

**IMPLEMENTACIÓN DE TÉCNICAS DE CARACTERIZACIÓN
EN SEÑALES EMG PARA EL RECONOCIMIENTO
AUTOMÁTICO DE ACTIVIDADES FÍSICAS HUMANAS**

Ing. Rodrigo Andrés Franco Luna

Proyecto de grado presentado como requisito parcial
para aspirar al título de Magíster en Ingeniería Eléctrica

Director

Ing. Andrés Felipe Calvo Salcedo, M.Sc.

**UNIVERSIDAD TECNOLÓGICA DE PEREIRA
FACULTAD DE INGENIERÍAS
PROGRAMA DE MAESTRÍA EN INGENIERÍA ELÉCTRICA
LINEA DE AUTOMÁTICA
PEREIRA
2019**

Nota de Aceptación

Firma del Presidente del jurado

Firma del jurado 1 - Evaluador

Firma del jurado 2 - Evaluador

Firma del jurado 3 - Director

Pereira, 15 de enero de 2019

Agradecimientos

Siempre he pensado que como personas somos una combinación no lineal de los que nos rodean, e incluso de las que ya no están; esto quiere decir que si tengo que agradecer la lista seria inmensamente grande pues en mi vida he contado con la bendición de tener personas a mi alrededor que me han valorado como persona, que han valorado mi amistad y hasta mis concejos, y como todo, los que nunca lo valoraron, pero eso solo me ha enseñado a apreciar las cosas simples de la vida.

En primera medida agradezco a Dios y a mi Madre, sin ellos en mi vida no habría camino, a mi hermana Analu la que ha sido mi compañera en este camino de crecimiento infantil de vida; a Jessica, mi compañera en esta nueva etapa de la vida, por la comprensión, la tolerancia y por darme lo mas bello que motiva mi vida día a día con esos dos motores hermosos, mis bendiciones, Gabriel y Miguel con los que entre juegos y pijamas escribí gran parte de este documento, a mi familia en general, pero en especial a mi tío Álvaro, que a falta de mi Padre (que siempre me cuida desde el cielo), él se ha comportado como ese ejemplo de amor paternal y guía.

Un agradecimiento sincero a todas esas personas que hicieron parte de mi camino académico hasta este punto, Luis Enrrique Avendaño, Jose Andres Chavez por su apoyo incondicional en el desarrollo del pregrado; a Mauricio Holguín y especialmente a Germán Holguín quienes me dieron la oportunidad de enfrentar esta etapa académica, por sus enseñanzas y su amistad, a Mauricio Álvarez, a Eduardo Giraldo, Gustavo Betancur, Julián Gil y muchos otros que siempre han estado ahí.

A esas personas que en el camino desvanecen y se iluminan pero siempre estan, con los que hemos alternado entre maestros y alumnos, algunas veces he sido su maestro, y en muchas otras ocasiones he sido orgulosamente su alumno, Juan Guillermo, Andrés Calvo, Johan Ñañez, Hugo Gerardo Gómez, Daniel Molina, Arley Bejarano, y muchas mas que no alcanzo a poner en este documento, no por que no los recuerde, sino por la premura de entregarlo, a todos Mil gracias.

CONTENIDO

pág.

TÍTULO

CONTENIDO

1. INTRODUCCIÓN	11
1.1. DEFINICIÓN DEL PROBLEMA	11
1.2. JUSTIFICACIÓN	13
1.3. OBJETIVOS	15
1.3.1. Objetivo General	15
1.3.2. Objetivos Específicos	15
2. ESTADO DEL ARTE	17
3. MARCO TEÓRICO	21
3.1. Transformada Wavelet Discreta (DWT)	21
3.2. Mel Frequency Cesptrum (MFCC)	21
3.3. Modelos Autorregresivos (AR)	22
3.4. Máquinas de soporte vectorial (SVM)	23
3.5. Máquinas de soporte vectorial multiclase	25
3.6. Modelos Ocultos de Markov (HMM)	25
4. MARCO CONCEPTUAL	29
4.1. Unidad de masa inercial (IMU)	29
4.2. Kinect	29
4.3. Electromiografía (EMG)	29
4.4. Extracción de características	30
4.5. Modelos Adaptativos	30

4.6.	Clasificación	31
4.7.	Clasificación no supervisada	31
4.8.	Clasificación supervisada	31
4.9.	Análisis de rendimiento de un clasificador	31
4.10.	Matriz de confusión	32
5.	METODOLOGÍA	35
5.1.	Adquisición y etiquetado de la de datos	36
5.2.	Conjunto de sensores multimodales	38
5.3.	Metodología de construcción de descriptores y experi- mentos	38
5.4.	Transformada rápida de Fourier (FFT)	40
5.5.	Coefficientes Auto regresivos (AR)	40
5.6.	Transformada Wavelet	41
5.6.1.	Coefficientes Wavelet de Aproximación y Detalle .	41
5.6.2.	Descomposición modal Wavelet	41
5.7.	Clasificación de Movimientos	43
6.	RECONOCIMIENTO DE ACTIVIDAD	45
7.	EXPERIMENTOS Y RESULTADOS	47
7.1.	Reconocimiento de Movimientos Primitivos	49
7.2.	Reconocimiento de actividades físicas	50
7.2.1.	Experimento EMG	51
7.2.2.	Experimento EMG+Kinect®	52
7.2.3.	Experimento EMG+IMU	52
7.2.4.	Experimento EMG+Kinect®+IMU	53
7.2.5.	Comparación de los desempeños de clasificación en la fusión de datos multimodal	54

8. CONCLUSIONES Y RECOMENDACIONES	57
8.1. CONCLUSIONES	57
8.2. RECOMENDACIONES	59
BIBLIOGRAFÍA	61
9. ANÉXOS	69
9.1. Matrices de Confusión movimientos primitivos	69
9.2. Matrices de Confusión actividades físicas	73
9.2.1. Experimento EMG	73
9.2.2. Experimento EMG+Kinect	77
9.2.3. Experimento EMG+IMU	81
9.2.4. Experimento EMG+Kinect+IMU	85

LISTA DE TABLAS

1.	Lista de actividades	37
2.	Etiquetas del SVM para cada postura	38
3.	Diagonales de las Matrices de confusión	50
4.	Matriz de Confusión EMG con todos los sensores	51
5.	Matriz de Confusión EMG+Kinect®	52
6.	Matriz de Confusión EMG+IMU	53
7.	Matriz de Confusión EMG+Kinect®+IMU	53
8.	Tabla de comparación descriptores implementados en los experi- mentos EMG y EMG+Kinect®	54
9.	Tabla de comparación descriptores implementados en los experi- mentos EMG+IMU y EMG+Kinect®+IMU	55

LISTA DE FIGURAS

1.	Metodología de identificación de actividades físicas	36
2.	Etapas del sistema de captura sincronizado	37
3.	Disposición de los sensores IMU y EMG sobre el sujeto de prueba .	39
4.	Descomposición Wavelet de una señal en coeficientes de detalle y aproximación (Imagen Obtenida de Mathworks-MATLAB)	42
5.	Matriz de confusión Actividades físicas - Descriptor CATAR	58
6.	Matrices de confusión Movimientos primitivos - Descriptor DFT (Izq. Señales Individuales - Der. Señales concatenadas)	69
7.	Matrices de confusión Movimientos primitivos - Descriptor AR (Izq. Señales Individuales - Der. Señales concatenadas)	69
8.	Matrices de confusión Movimientos primitivos - Descriptor Wavelet concatenado coeficientes de aproximación y detalle (Izq. Señales Individuales - Der. Señales concatenadas)	70
9.	Matrices de confusión Movimientos primitivos - Descriptor Wavelet descomposición de orden superior (Izq. Señales Individuales - Der. Señales concatenadas)	70
10.	Matrices de confusión Movimientos primitivos - Descriptor Wavelet FFT (Izq. Señales Individuales - Der. Señales concatenadas) . . .	71
11.	Matrices de confusión Movimientos primitivos - Descriptor Wavelet AR (Izq. Señales Individuales - Der. Señales concatenadas)	71
12.	Matrices de confusión Movimientos primitivos - Descriptor Wavelet Estadísticos (Izq. Señales Individuales - Der. Señales concatenadas)	72
13.	Matrices de confusión Movimientos primitivos - Wavelet Estadísti- cos y energía (Izq. Señales Individuales - Der. Señales concatenadas)	72

14.	(Experimento EMG) Matrices de confusión Actividades físicas - Descriptor DFT (Izq. Señales Individuales - Der. Señales concatenadas)	73
15.	(Experimento EMG) Matrices de confusión Actividades físicas - Descriptor AR (Izq. Señales Individuales - Der. Señales concatenadas)	73
16.	(Experimento EMG) Matrices de confusión Actividades físicas - Descriptor Wavelet concatenado coeficientes de aproximación y detalle (Izq. Señales Individuales - Der. Señales concatenadas) . . .	74
17.	(Experimento EMG) Matrices de confusión Actividades físicas - Descriptor Wavelet descomposición de orden superior (Izq. Señales Individuales - Der. Señales concatenadas)	74
18.	(Experimento EMG) Matrices de confusión Actividades físicas - Descriptor Wavelet FFT (Izq. Señales Individuales - Der. Señales concatenadas)	75
19.	(Experimento EMG) Matrices de confusión Actividades físicas - Descriptor Wavelet AR (Izq. Señales Individuales - Der. Señales concatenadas)	75
20.	(Experimento EMG) Matrices de confusión Actividades físicas - Descriptor Wavelet Estadísticos (Izq. Señales Individuales - Der. Señales concatenadas)	76
21.	(Experimento EMG) Matrices de confusión Actividades físicas - Wavelet Estadísticos y energía (Izq. Señales Individuales - Der. Señales concatenadas)	76
22.	(Experimento EMG+Kinect) Matrices de confusión Actividades físicas - Descriptor DFT (Izq. Señales Individuales - Der. Señales concatenadas)	77

23.	(Experimento EMG+Kinect) Matrices de confusión Actividades físicas - Descriptor AR (Izq. Señales Individuales - Der. Señales concatenadas)	77
24.	(Experimento EMG+Kinect) Matrices de confusión Actividades físicas - Descriptor Wavelet concatenado coeficientes de aproximación y detalle (Izq. Señales Individuales - Der. Señales concatenadas) .	78
25.	(Experimento EMG+Kinect) Matrices de confusión Actividades físicas - Descriptor Wavelet descomposición de orden superior (Izq. Señales Individuales - Der. Señales concatenadas)	78
26.	(Experimento EMG+Kinect) Matrices de confusión Actividades físicas - Descriptor Wavelet FFT (Izq. Señales Individuales - Der. Señales concatenadas)	79
27.	(Experimento EMG+Kinect) Matrices de confusión Actividades físicas - Descriptor Wavelet AR (Izq. Señales Individuales - Der. Señales concatenadas)	79
28.	(Experimento EMG+Kinect) Matrices de confusión Actividades físicas - Descriptor Wavelet Estadísticos (Izq. Señales Individuales - Der. Señales concatenadas)	80
29.	(Experimento EMG+Kinect) Matrices de confusión Actividades físicas - Wavelet Estadísticos y energía (Izq. Señales Individuales - Der. Señales concatenadas)	80
30.	(Experimento EMG+IMU) Matrices de confusión Actividades físicas - Descriptor DFT (Izq. Señales Individuales - Der. Señales concatenadas)	81
31.	(Experimento EMG+IMU) Matrices de confusión Actividades físicas - Descriptor AR (Izq. Señales Individuales - Der. Señales concatenadas)	81

32.	(Experimento EMG+IMU) Matrices de confusión Actividades físicas - Descriptor Wavelet concatenado coeficientes de aproximación y detalle (Izq. Señales Individuales - Der. Señales concatenadas) .	82
33.	(Experimento EMG+IMU) Matrices de confusión Actividades físicas - Descriptor Wavelet descomposición de orden superior (Izq. Señales Individuales - Der. Señales concatenadas)	82
34.	(Experimento EMG+IMU) Matrices de confusión Actividades físicas - Descriptor Wavelet FFT (Izq. Señales Individuales - Der. Señales concatenadas)	83
35.	(Experimento EMG+IMU) Matrices de confusión Actividades físicas - Descriptor Wavelet AR (Izq. Señales Individuales - Der. Señales concatenadas)	83
36.	(Experimento EMG+IMU) Matrices de confusión Actividades físicas - Descriptor Wavelet Estadísticos (Izq. Señales Individuales - Der. Señales concatenadas)	84
37.	(Experimento EMG+IMU) Matrices de confusión Actividades físicas - Wavelet Estadísticos y energía (Izq. Señales Individuales - Der. Señales concatenadas)	84
38.	(Experimento EMG+Kinect+IMU) Matrices de confusión Actividades físicas - Descriptor DFT (Izq. Señales Individuales - Der. Señales concatenadas)	85
39.	(Experimento EMG+Kinect+IMU) Matrices de confusión Actividades físicas - Descriptor AR (Izq. Señales Individuales - Der. Señales concatenadas)	85
40.	(Experimento EMG+Kinect+IMU) Matrices de confusión Actividades físicas - Descriptor Wavelet concatenado coeficientes de aproximación y detalle (Izq. Señales Individuales - Der. Señales concatenadas)	86

41.	(Experimento EMG+Kinect+IMU) Matrices de confusión Actividades físicas - Descriptor Wavelet descomposición de orden superior (Izq. Señales Individuales - Der. Señales concatenadas)	86
42.	(Experimento EMG+Kinect+IMU) Matrices de confusión Actividades físicas - Descriptor Wavelet FFT (Izq. Señales Individuales - Der. Señales concatenadas)	87
43.	(Experimento EMG+Kinect+IMU) Matrices de confusión Actividades físicas - Descriptor Wavelet AR (Izq. Señales Individuales - Der. Señales concatenadas)	87
44.	(Experimento EMG+Kinect+IMU) Matrices de confusión Actividades físicas - Descriptor Wavelet Estadísticos (Izq. Señales Individuales - Der. Señales concatenadas)	88
45.	(Experimento EMG+Kinect+IMU) Matrices de confusión Actividades físicas - Wavelet Estadísticos y energía (Izq. Señales Individuales - Der. Señales concatenadas)	88

1. INTRODUCCIÓN

El desarrollo de metodologías sobre la identificación de actividades físicas es un sector de investigación muy activo en la actualidad que intensiva a grupos de investigación y centros al desarrollo de metodologías e incluso tecnologías para lograr identificarlas.

En este documento se exploran metodologías para la detección automática de actividades físicas, muchas de las metodologías exploran implementaciones basada en la fusión de sensores introduciendo un concepto denominado fusion multimodal (sera ampliada mas adelante) que busca tratar de identificar una actividad con el uso de múltiples sensores obteniendo desempeño de los clasificadores muy interesantes.

Se busca realizar una validación tanto metodología como estadística sobre los descriptores de señales que presenten mejores características en el desempeño, y de igual manera impulsar el desarrollo de metodologías multimodales, pues la etapa de descripción en los sistemas de aprendizaje es sumamente sensible para el desempeño de un clasificado.

1.1. DEFINICIÓN DEL PROBLEMA

El ser humano se ha caracterizado por tener la capacidad de identificar patrones con el uso de su inteligencia, algunos de los patrones son verdaderos (identificar una lluvia) y en muchos casos falsos (ver rostros en las nubes), pero esa es la finalidad de la ciencia, identificar aquellos patrones que son reales y generales. La ciencia, como eje del desarrollo del conocimiento, mas allá de permitir que el hombre conozca cada día mas el mundo que lo rodea, permite ,de igual manera, que mejore la calidad de vida; y la calidad de vida se puede ver desde diversos putos de vista, pero los mas evidentes son los que tienen que ver directamente con la salud física y mental del hombre. El reconocimiento de actividades físicas es una habilidad totalmente natural para el ser humano, y lograr que un sistema automático sea capaz de realizar dicha identificación se considera un gran desafío, y hoy en día es una motivación para diversos grupos de investigación en proponer aplicaciones y desarrollos que apoyen los proceso medico mejorando cada vez mas los resultados [1, 2, 3].

En la actualidad, el análisis de la actividad física ha permitido desarrollar dispositivos y aplicaciones en áreas como la salud [4] y el deporte, detectando la predisposición a enfermedades como parkinson o epilepsia [1], vigilar la salud de los adultos mayores [5], realizar la rehabilitación física de pacientes [6], vigilar la evolución del rendimiento físico de deportistas [6]; en la robótica, la construcción de prótesis mecánicas [7], entre otras áreas de investigación.

Desde la ingeniería y las ciencias de la computación, el reconocimiento de la actividad física humana a tenido como objetivo automatizar la identificación de diferentes tipos de movimientos físicos a partir de un conjunto de medidas obtenidas a través de redes de sensores[8, 6, 9]. Estas medidas pueden ser captadas por cámaras, sensores de profundidad, sensores electrocardiógrafos (ECG), goniómetros, giroscopios (Sensores angulares), acelerómetros, sensores electromiográficos (EMG), e incluso sensores electroencefalógrafos (EEG).

Un enfoque común en el desarrollo de metodologías automáticas¹ involucra, en muchos casos, técnicas de procesamiento digital de imágenes, visión por computador y visión de maquina usando un sin numero de técnicas para la caracterización y procesamiento de imágenes [10, 11, 12], en la actualidad (2018), existen dispositivos que llevan el procesamiento digital de imágenes a niveles muy asequibles para todas las personas como el sensor Kinect®. Algunas metodologías utilizan sensores de movimiento como acelerómetros, giroscopios o unidades de masa inercial (IMU) [13, 14, 15], electrodos de registro electromiográfico (EMG) [16, 17], información obtenida desde el procesamiento de imágenes con Kinect®. En 2015, Calvo y Holguín [8], presentan una metodología que realiza la fusión de los sensores más utilizados para el reconocimiento de actividades físicas, Kinect®, los IMU y los EMG, lo que se denomina ***fusión multimodal***², este es uno de los enfoques que permite mejorar el factor discriminante de una observación aprovechando las ventajas individuales de cada sensor [18, 19, 20, 21], y de igual manera proponen que cada movimiento se divida en unos movimientos mas pequeños que se denominan ***movimientos primitivos***, donde varias actividades físicas podrían tener en común uno o varios movimientos primitivos.

¹Las metodologías automáticas son aquellas metodologías que realizan una acción determinada sin la intervención directa del hombre dentro del proceso.

²La fusión multimodal es fundamentalmente el uso de múltiples sensores de diferentes naturalezas para medir un mismo conjunto de fenómenos.

Algunas de las técnicas usadas en el proceso de caracterización usando técnicas como Mean Absolute Value (MAV) [22, 9], transformadas Wavelets [9, 23, 24, 25, 26], Mel Frequency Cepstrum [27, 17, 28, 25, 26], entre otros [29, 30], logrando resultados hasta del 98 % en la identificación de actividades físicas, sin embargo, se evidencia la necesidad de desarrollar metodologías más eficientes en la caracterización, pues en los resultados asociados a las señales EMG se evidencia una debilidad en los desempeños de los clasificadores, especialmente sobre las señales de EMG.

Morales y Calvo[31] en 2016, exploran el proceso de identificación con los mismos grupos de sensores (Kinect®, IMU y EMG) con enfoque en metodologías de aprendizaje no supervisado, para este proceso se utilizan técnicas de agrupamiento como Spectral Clustering y K-means clustering, junto con técnicas como Hidden Markov Model (HMM). Gracias al procedimiento planteado por Morales y Calvo [31], se logra determinar que solo son necesarios 5 movimientos primitivos para detectar todo el conjunto de actividades físicas, reduciendo la complejidad que provoca al utilizar más clases como era propuesto por Calvo y Holguín [8]. Aunque las metodologías planteadas presentan desempeños por encima del 95 % en promedio.

Sin embargo, incluso con la presentación de los desempeños superiores al 95 %, con el análisis de los resultados de identificación asociados a las señales EMG son bajos, por tanto se evidencia la posibilidad de realizar un amplio estudio sobre la caracterización de las señales EMG que puedan, como primera medida, reducir los efectos del ruido y además mejorar la capacidad de identificación.

1.2. JUSTIFICACIÓN

Ya que el reconocimiento de las actividades físicas es de alta importancia para diferentes áreas de investigación y desarrollo, se evidencia un creciente interés en desarrollar aplicaciones que permitan el monitoreo y la detección de un conjunto amplio de actividades físicas humanas [8, 31, 9]. En la literatura [10, 13, 1, 3, 32, 33, 34, 31, 8] se han desarrollado múltiples metodologías donde se utilizan diferentes modalidades de sensores, metodologías multimodales con enfoques supervisados y no supervisados que han permitido identificar las bondades de la

fusión de sensores, pero de la misma manera, el potencial de las señales EMG en el proceso de identificación.

Un sistema de clasificación consta de 4 etapas [23]; Inicialmente, se basa en la detección de la señal, seguido de la extracción de características, reducción de la dimensionalidad y finalmente la clasificación.

En la etapa de detección de la señal se usan gran gama de sensores basados en principios físicos, que mediante un proceso de transducción, transforman y acondicionan la señal de interés en una señal de naturaleza eléctrica susceptible de ser capturada por un computador, de esta etapa se encarga la instrumentación [17]. La segunda etapa es una de las linea de la ciencia computacional, y trata sobre la aplicación de técnicas matemáticas para realizar la extracción de características de una señal acondicionada (también conocida en la literatura como *Raw Data* - datos sin procesar [4, 35, 26]). Los descriptores que se obtienen por medio de la etapa anterior (extracción de características) pueden contener información redundante e irrelevante que aumenta la dimensionalidad y degrada la calidad del espectro [17], en ese orden de ideas, la etapa tres busca implementar técnicas que analizan las contribuciones de los descriptores y penalizar las características irrelevantes en pro de una separación mas optima de las clases, y a su vez, reduce la carga computacional del proceso de identificación[36]. Finalmente, la etapa de clasificación, usa las características extraídas y afinadas para realizar la identificación del fenómeno.[37].

Cada etapa juega un papel importante en el proceso de identificación, sin embargo, una de las etapas mas sensibles del proceso, es la etapa de la extracción de características [27, 36, 17, 23, 38, 25], y como lo demostró Calvo y Holguín [8] en 2015 y Morales y Calvo [31] en 2016, la fusión de sensores multimodales brinda un camino claro en el proceso de identificación de las actividades humanas desde el enfoque supervisado y no supervisado, al igual que se identifica una oportunidad de obtener mas información relevante desde las señales EMG explorando nuevas metodologías y combinaciones de ellas para la generación de descriptores que mejoren el proceso de identificación. La comunidad científica que realiza su investigación al rededor de las señales EMG para clasificación proponen que las características fusionadas sobre estas

señales presentan mucha solidez, especialmente, cuando se desconocen el mejor conjunto de características[17], y plantean que aún existen desafíos considerables en la caracterización de las señales de EMG en *raw data* aplicables a los proceso de aprendizaje de maquina [8, 31, 17, 25].

Por lo anterior, el desarrollo de este trabajo se basa en la identificación de conjuntos de metodologías sobre señales EMG que puedan ser combinadas y fusionadas con los IMU y los puntos de articulación de Kinect® para la construcción de descriptores mas robustos sobre las señales de los sensores EMG con los cuales se permitan mejorar el desempeño del proceso de identificación y clasificación de las actividades físicas humanas propuestas por Calvo en 2015 [8] y por Morales en 2016 [31].

1.3. OBJETIVOS

1.3.1. Objetivo General

Comparar diferentes metodologías de caracterización de señales EMG para la construcción de descriptores en la detección automática de actividades físicas humanas.

1.3.2. Objetivos Específicos

1. Implementar los algoritmos de caracterización seleccionados sobre las señales EMG.
2. Construir los descriptores para el sistema de identificación.
3. Realizar una comparación estadística del desempeño de los descriptores implementados sobre las señales EMG usando el análisis de las matrices de confusión.

2. ESTADO DEL ARTE

El estudio de las señales de EMG en las ciencias de la computación, han permitido desarrollar diferentes investigaciones sobre el uso de estas en la identificación de la actividad física humana, la salud, la robótica y en muchos otros campos. A continuación, se realiza un recorrido por los avances y contribuciones hechas al desarrollo de aplicaciones sobre este tipo de señales, aplicadas a la identificación automática de actividades físicas humanas en un ambiente no estructurado.

Los sensores electromiográficos (EMG) han sido ampliamente utilizados en el reconocimiento de actividades, sin embargo estos presentan dos configuraciones [16, 28, 39, 26], la primera es intramuscular que hace necesario el implante de sensores dentro del cuerpo, aspecto que es sumamente invasivo para los sujetos de estudio, este tipo de señales se conocen como iEMG, y la segunda manera de obtener es por medio del uso de sensores superficiales, estas señales se denominan sEMG. No se va a considerar el uso de sensores invasivos, por tanto en adelante llamaremos a las señales sEMG simplemente señales EMG.

Los primeros en clasificar estas señales EMG con razonable éxito (un acierto superior al 75 %) fueron Graupe y Cline en 1975 [40], ellos utilizaron técnicas de caracterización como Mean Absolute Value (MAV), este enfoque fue retomado en varios trabajos entre los cuales se destaca el de Bingken y Shiyu en 2016 [6], Khushaba et. al. en el mismo año [25] y Bhattacharya y Sarkar en 2017 [22]. En 1983 Doerschuck, utilizando las mismas técnicas desarrolladas por Graupe [40], incluyendo técnicas de correlación entre múltiples electrodos lograron un 83.5 % de acierto [41]. En 1995 W. Kang utilizó MFCC (Mel-Frequency Cepstral Coefficients) obteniendo un acierto del 85 % [42], método que también fue retomado en la caracterización por trabajos realizados en 1996 por Lee y Kim [27], en 2013 por Zhaojie et. al. [26], y por varios autores en 2016 [17, 28, 25].

En la extracción de características de las señales EMG se han usado gran cantidad de metodologías asociadas a la teoría de las señales, estas se pueden dividir en tres grandes grupos [17]. El primero es el enfoque estadístico, el segundo es un enfoque temporal y finalmente el

enfoque en descomposición en frecuencia o espectral. Dentro del enfoque estadístico se puede destacar el valor absoluto promedio (MAV) [6], calculo de la entropía [16, 28, 25], estudios demostraron que los momentos estadísticos calculados a partir de las señales EMG contienen información útil para el proceso de clasificación de dichas señales [16]. Dentro de los temporales se destaca el valor RMS [36, 23, 22, 28], y el análisis de variaciones de la señal (derivadas de primer y segundo orden) [25], en algunos trabajos han intentado usar las señales EMG sin ningún procesamiento (*raw data*), sin embargo se ha demostrado que la caracterización mejora sustancialmente la identificación, reduce el ruido de medida y la redundancia [6, 17]. Dentro de enfoque espectral se podría encontrar técnicas como MFCC [27, 17, 28, 25, 26], Modelos AR [16, 6, 36, 17, 23, 24, 22, 35, 39, 26], la descomposición modal empírica [43] y la Transformada de Fourier y sus variaciones (DFT y STFFT) [9, 17, 23, 28, 35, 43, 25, 26], la implementación de la transformada de Fourier de tiempo corto (STFFT), es un descriptor obligado en la caracterización de señales, además de ser ampliamente usado sobre señales EMG [9, 17, 23, 28, 35, 43, 25, 26]. También se han aplicado descriptores basados en combinaciones tiempo-frecuencia donde la metodología mas relevante es la transformada Wavelets [29, 44, 30, 16, 9, 17, 23, 24, 4, 35, 43, 25, 26], obteniendo resultados mayores al 90% de acierto y algunas derivaciones como el calculo de su energía [16]. Todas las anteriores técnicas aplicadas sobre metodologías de fusión de datos para la construcción de descriptores mas robustos en la clasificación, pues la fusión de datos presenta mucha solidez en aplicaciones reales, especialmente cuando se desconoce el mejor conjunto de características [17].

Sin embargo muchos autores coinciden en que las señales EMG son complejas en su tratamiento debido a que presentan una alta dependencia de la configuración del experimento [17] y que varían de manera considerable de persona a persona en la combinación muscular para un mismo movimiento y la potencia de la señales EMG emitida [23, 38]. Además de que también presenta características NO estacionarias muy marcadas que han dificultado la clasificación y han hecho necesario involucrar nuevas técnicas, además de mejorar y adaptar muchas de las ya existentes [27, 6, 9, 17, 23, 28]. Por tanto, debido a que la extracción de características es el núcleo principal de los sistemas de clasificación [27, 36, 17, 23, 38, 25], se evidencia

una oportunidad especial en el desarrollo de metodologías de caracterización sobre las señales EMG, pues estas presentan un gran desafío para definir el mejor conjunto de características para la clasificación [17].

En la actualidad se presenta un enfoque basado en metodologías adaptativas, pues estos brindan una extracción mas precisa y estable, especialmente sobre las señales EMG [27, 4, 28, 35], ademas los métodos adaptativos están poco desarrollados, y solo en la actualidad están presentando un interés general en la comunidad científica para su uso en la caracterización de señales EMG [27].

Una constante en el desarrollo del estado del arte sobre la caracterización de la señales EMG en la actualidad, es el uso de modelos adaptativos; dentro de estos, se han identificado dos técnicas que han sido evaluadas para la clasificación y han presentado desempeños por encima del 90 %, pero aún no han sido fusionadas ni usadas en el contexto de la identificación de movimiento humanos, estas van a ser ampliadas a continuación.

La primera técnica con la componente adaptativa corresponde a la transformada Wavelet [16, 9, 17, 23, 24, 4, 35, 43, 25, 26], esta técnica, por defecto, ya presenta muy buenos resultados en la caracterización y promete ser un método muy efectivo para analizar señales dinámicas [9, 22], aunque presenta una dependencia de la selección de la onda madre [17], sin embargo son muy efectivas en la reducción del ruido. La adición de la característica adaptativa podría hacer que el descriptor sea mas robusto y presente mejores resultados en la clasificación.

En segunda estancia, los modelos AR (Modelos Autorregresivos) [16, 6, 36, 17, 23, 24, 22, 35, 39, 26], permiten ajustar modelos lineales y no lineales, los cuales proporcionar información complementaria que puede representar eficientemente las características dinámicas de señales EMG, facilitando también, la implementación de regresiones no lineales múltiples. Por medio de los modelos AR de orden 6 se pueden obtener características que presentan desempeños de clasificación por encima del 90 % por si solos, y en muchos casos superiores a los presentados por la STFFT y Wavelets, adicionalmente brindan robustez al desplazamiento de los electrodos EMG [23, 22]. los modelos AR no lineales son una tendencia en la extracción de características [26].

3. MARCO TEÓRICO

3.1. Transformada Wavelet Discreta (DWT)

Esta técnica nace como una alternativa para superar los problemas de resolución de la transformada de Fourier de tiempo corto (STFT), haciendo posible una buena representación de una señal tanto en tiempo como en frecuencia de forma simultánea. Básicamente, la idea de la transformada Wavelet es filtrar una señal en el dominio del tiempo mediante filtros paso bajo y paso alto para eliminar ciertas componentes de alta o baja frecuencia de la señal, el procedimiento se repite para las señales resultantes del proceso de filtrado y a esta operación se le denomina descomposición [45].

Dada la función discreta $f[n]$, la cual se define como la señal a analizar, su transformada Wavelet $c[i, k]$, se define como:

$$c[i, k] = f[n] \Psi_{i,j}[n] \quad (1)$$

Donde, $\Psi_{i,j}$ es una Wavelet discreta definida como:

$$\Psi_{i,j}[n] = 2^{-\frac{j}{2}} \cdot \Psi[2^{-j}n - k] \quad (2)$$

Los parámetros τ y s , están definidos según la escala diádica, de manera que:

$$\tau = 2^j \quad (3)$$

$$s = 2^j k \quad (4)$$

3.2. Mel Frequency Cesptrum (MFCC)

Es una técnica de caracterización introducida por Davis y Mermelstein (D&M) en 1980 [15], la cual consiste en combinar filtros triangulares y perceptualmente distribuidos, con la transformada discreta del coseno del logaritmo de las energías de salida de los filtros. El procedimiento

de cálculo de los MFCCs se basa en el siguiente procedimiento [46, 47]:

Segmentar la señal utilizando ventanas, luego a cada segmento, se le debe aplicar la transformada de Fourier discreta (DFT), después se aplica el banco de filtros correspondientes a la escala Mel, al espectro obtenido en el paso anterior y sumar las energías en cada uno de ellos, por último se calcula el logaritmo de todas las energías de cada frecuencia Mel y se aplica la transformada de Coseno discreta a estos logaritmos.

La ecuación que permite el cálculo de estos coeficiente se define como:

$$MFCC_i = \sum_{k=1}^{n_f} X_k \cos \left[i \left(k - \frac{1}{2} \right) \frac{\pi}{n_f} \right] \quad (5)$$

Donde:

- i es el número de coeficientes a calcular.
- X_k es el logaritmo de la energía de salida del filtro k –ésimo.
- n_f es el número de filtros a utilizar en la transformada.

3.3. Modelos Autorregresivos (AR)

Decimos que la serie de tiempo $u(n), u(n-1), \dots, u(n-M)$, representa la realización de un modelo autoregresivo (AR) de orden M , si este satisface la ecuación en diferencias presentada en la ecuación (6).

$$u(n) + a_1^* u(n-1) + a_M^* u(n-M) = v(n) \quad (6)$$

Donde a_1, a_2, \dots, a_M son contantes llamadas *los parámetros AR*, y $\{v(n)\}$ es el ruido blanco del proceso. Los términos $a_k^* u(n-k)$ es el producto interno de a_k y $u(n-k)$, donde $k = 1, 2, \dots, M$. para poder explicar porque el nombre de “Autoregresivo”, se reescribirá la ecuación 6 de la siguiente forma.

$$u(n) = w_1^* u(n-1) + w_2^* u(n-2) + \dots + w_M^* u(n-M) + v(n) \quad (7)$$

Donde $w_k = -a_k$. Así que el valor presente del proceso, es decir, $u(n)$, es igual a una combinación lineal finita de valores pasados del proceso $u(n-1), u(n-2), \dots, u(n-M)$, adicionando un termino de error $v(n)$. Ahora se puede observar la razón por la que recibe el nombre de “Autoregresivo”. Específicamente, un modelo lineal se puede ver como.

$$y = \sum_{k=1}^M w_k^* x_k + v \quad (8)$$

Relacionando una variable dependiente y , con un conjunto de variable independientes x_1, x_2, \dots, x_M , mas un termino de error v , a menudo se conoce como un modelo de regresión, y y se a dicho que es la obtenida a través de x_1, x_2, \dots, x_M . En la ecuación 7, la variable $u(n)$ es obtenida a través de valores previos de si misma, de ahí el nombre de “Autorregresivos”. [48]

3.4. Máquinas de soporte vectorial (SVM)

Las máquinas de soporte vectorial son una metodología de clasificación asistida basada en la teoría de Vapnik [37]. Este método tiene como objetivo la estimación de un modelo de aprendizaje que permita la clasificación de un evento binario, su formulación matemática depende de la naturaleza de los datos; es decir que existen diferentes formulaciones dependiendo de la linealidad o de la distribución de sus datos. En su forma más sencilla una SVM tiene como objetivo encontrar el hiperplano que separe y maximice el margen entre las clases en este espacio [49].

La SVM se considera un clasificador binario, el cual calcula una etiqueta $y \in \{-1, 1\}$ utilizando el siguiente modelo:

$$y = w^T \phi(x) + b \quad (9)$$

Donde, $\phi(x) : \mathbb{R} \rightarrow H$ es una transformación del conjunto de entrada a un conjunto con igual o mayor dimensión, lo que se supone que facilita la separación de las clases. El vector w define

el hiperplano de separación en el espacio $\phi(X)$. b representa el bias o sesgo con respecto al origen de coordenadas. La SVM aborda el problema de clasificación relajando el concepto de margen, para lo que se introduce variables de sesgo $\xi_i \geq 0$, donde la función de costo se define como:

$$c(y, f(x, w)) = \begin{cases} 0 & \text{si } y = \text{sing}(w^T \phi(x) + b) \\ 1 & \text{si } y \neq \text{sing}(w^T \phi(x) + b) \end{cases} \quad (10)$$

Donde existe el riesgo empírico $R_{emp} = \sum_{i=1}^n \xi_i^\sigma$, Siendo generalmente $\sigma = 1$ en problema de clasificación. Por lo tanto el problema de estimación del hiperplano de separación, se define como la solución al siguiente problema de optimización cuadrático (QP):

$$\min_{w, b, \xi_i} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \xi_i \quad (11)$$

$$\text{Sujeto a } y_i (w^T \phi(x_i) + b) \geq 1 - \xi_i \quad \forall i = 1, \dots, n \quad (12)$$

$$\xi_i \geq 0 \quad \forall i = 1, \dots, n \quad (13)$$

Donde, x_i es una muestra del conjunto de entrenamiento con su respectiva etiqueta y C se define como una constante de regularización. Buscando el hiperplano óptimo en (12), se requiere resolver un problema QP, que puede ser resuelto construyendo un Lagrangiano y transformándolo en el dual. Por lo que el problema de optimización se define como:

$$\max_{\alpha_i} L_D = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j \phi^T(x_i) \phi(x_j) \quad (14)$$

$$\text{sujeto a } \sum_{j=1}^n \alpha_j y_j = 0 \quad (15)$$

$$0 \leq \alpha_i \leq C \quad \forall i = 1, \dots, n \quad (16)$$

3.5. Máquinas de soporte vectorial multiclase

Las SVM , originalmente son clasificadores formulados para problemas binarios, donde solo existen 2 clases, no obstante, en la práctica es común encontrar problemas en los que se debe clasificar $k > 2$ distintas. Por lo que existen diferentes metodologías para lograr una extensión de las SVM a la clasificación multiclase.

Entre las metodologías más comunes se encuentran los siguientes enfoques [50]:

Uno contra todos: Esta estrategia consiste en la estimación de una SVM por clase, la cual está capacitada para distinguir el conjunto de datos que pertenece a clase en particular del conjunto de datos de todas las clases restantes. Por lo general, una sola clase debe detectar positivo un ejemplo, cuando más de un modelo SVM clasifica un conjunto de datos positivo, se calcula la probabilidad de pertenencia a la clase y se escoge la clase con máxima probabilidad.

Uno contra uno: Esta estrategia de clasificación consiste en construir un clasificador por par de clases, la pertenencia a la clase se encoje buscando la clase que recibió la mayoría de votos, en caso de un empate, entre dos clases con el mismo número de votos, se calcula la probabilidad de pertenencia a la clase y se escoge la clase con máxima probabilidad. Para implementar esta metodología se requiere de m clasificadores, este método es generalmente más lento que uno contra todos. Sin embargo, este método puede ser ventajoso cuando se utiliza *kernel* que no se escalan bien con n muestras. El cálculo de m se define como:

$$m = \frac{n_{classes}(n_{classes} - 1)}{2}$$

3.6. Modelos Ocultos de Markov (HMM)

Los HMM son autómatas de estados finitos que permiten modelar procesos estocásticos, donde la transición a un estado en particular depende de una distribución de probabilidad. Los estados no son visibles en general y su ocurrencia depende del estado anterior. Esta metodología, asume que el sistema a modelar es un proceso de Markov de parámetros desconocidos y

su objetivo es determinar estos parámetros a partir de diferentes observaciones [51]. Un HMM se define como:

$$\lambda = f(O, Q, A, B, \pi)$$

Donde, $O = \{O_1, O_2, \dots, O_M\}$ son los estados visibles, $Q = \{1, 2, \dots, N\}$ son los estados ocultos. $A = \{a_{ij}\}$ es la matriz de transición de estados, donde el elemento a_{ij} es la probabilidad de que genere la transición desde el estado i al estado j , $B = \{b_i(k)\}$ se define como la matriz de probabilidad de salida, donde $b_i(k)$ es la probabilidad de emitir el símbolo O_k en el estado i , $\pi = \{\pi_i\}$ es el vector de probabilidades del estado inicial, donde π_i es la probabilidad de iniciar en el estado i .

Los tres problemas básicos de los HMM

Cuando se utilizan Modelos ocultos de Markov es necesario plantear tres problemas básicos, donde la solución de ellos permite, que esta metodología sea adecuada para representar la señal [51]:

El problema de la evaluación: Calcular eficientemente $P(O|\lambda)$ la probabilidad de la secuencia de observación O dado el modelo $\lambda = (A, B, \pi)$ y la secuencia de observación $O = \{O_1, O_2, \dots, O_T\}$. Entonces dado un modelo y una secuencia de observaciones de la señal, la evaluación se reduce a calcular probabilidad de que dicha secuencia de observaciones haya sido generada por el modelo. Es posible solucionar este problema utilizando la técnica de avance-retroceso.

El problema de la decodificación: Encontrar la trayectoria $q = (q_1, q_2, \dots, q_T)$ más probable dado el modelo λ y la secuencia de observación $O = \{O_1, O_2, \dots, O_T\}$. Dado un modelo y una secuencia de observaciones, ¿Cuál es número de estados óptimo que se debe seguir para generar una salida igual o similar a la secuencia de observaciones?. Para solucionar este problema se calcula la máxima verosimilitud.

El problema del aprendizaje: Ajustar los parámetros A, B, π con el fin de maximizar $P(O|\lambda)$. Para la solución de este problema, se utiliza un procedimiento iterativo llamado Método de Baum-Welch. En general, todo el Modelo de Markov es caracterizado por la pro-

babilidad de la observación del vector $b_j(O_t)$ para el k -ésimo elemento de emisión en cada estado j , la probabilidad de transición del estado a_{ij} que describe como el nuevo estado j puede ser alcanzado desde el anterior estado i , y la probabilidad del estado inicial π , indica la probabilidad que el i -ésimo estado, es el estado inicial de transición.

Libro de Código (codebook): Es el proceso de transformar el contenido del conjunto de entrenamiento en una representación codificada, donde se analiza cierta cantidad de muestras y se busca elementos que pueda ser agrupados y representados como un solo código. Este procedimiento es llevado a cabo reuniendo los patrones típicos de la señal y designando un código a cada patrón. Esta cuantificación trae consigo la idea de clasificar los patrones y luego buscar, los mejores representantes para reducir el tamaño del conjunto de entrenamiento. Para realizar el agrupamiento en el libro de códigos, se utilizan algoritmos basados en clustering, la técnica de K-means, permite ubicar y calcular los centroides de los vectores de observación, agrupando estos en torno a K valores medios arrojando como resultado un libro de códigos o codebook [51].

4. MARCO CONCEPTUAL

4.1. Unidad de masa inercial (IMU)

Una unidad de medición inercial, es un sensor electrónico que mide aceleración, orientación y fuerzas gravitacionales ejercidas sobre el dispositivo, usando la combinación de acelerómetros y giroscopios. Las unidades de medición inercial son normalmente usadas para aplicaciones de control e instrumentación, en el análisis de vibraciones y estimación de la posición y orientación de un objeto [52].

4.2. Kinect

El Kinect es un dispositivo diseñado para la detección de movimiento e interacción de un usuario con la consola de videojuegos Xbox 360. Es desarrollado por la empresa Microsoft® y permite a los usuarios controlar e interactuar con la consola sin necesidad de tener contacto físico. Este dispositivo puede proporcionar una variedad de datos basado en la información de una escena, entre algunas de sus características más importantes, se encuentra el mapa de profundidad de la escena, el cálculo de los puntos articulados de la silueta humana, entre otros [53].

4.3. Electromiografía (EMG)

La electromiografía es una técnica para medir la actividad eléctrica producida por los músculos esqueléticos. EMG, se desarrolla utilizando electrodos de superficie los cuales miden la actividad muscular esquelética transmitida a la superficie de la piel, obteniendo así un nivel de voltaje en el punto de medido. Este tipo de sensor, sólo permite evidenciar la contracción o relajación de conjunto de músculos medidos, no recogiendo directamente la actividad de las diferentes unidades motoras. Este tipo electrodo es el más utilizado para recolectar este tipo de medidas y consiste en un adhesivo que se adhiere a la piel permitiendo capturar la actividad eléctrica de los músculos donde el sensor fue ubicado[54].

4.4. Extracción de características

Consiste en la búsqueda de atributos o cualidades que facilitan la identificación de una entidad en particular, como fenómenos físicos, comportamientos, movimientos, entre otros. En el caso específico de las ciencias de computación e ingeniería, la extracción de características, se realiza aplicando descriptores matemáticos. Los descriptores matemáticos dependen específicamente de la naturaleza de los datos a analizar. Algunos de los descriptores más comunes son los: temporales, espaciales, representaciones en frecuencia, bases ortogonales, entre otros [55].

4.5. Modelos Adaptativos

En la implementación de técnicas matemáticas sobre señales en la ingeniería generalmente se asumen múltiples elementos, dentro de estos se resaltan dos, la primera asumir que la señal es estacionaria, y la segunda, la presunción de que la señal es periódica, sin embargo esto no es cierto en todos los casos. Técnicas como la transformada discreta de Fourier (DFT), y la transformada de tiempo corto de Fourier (STFFT) implican directa mente el uso de una ventana de datos para evitar que en el resultado del espectro aparezcan coeficientes de frecuencia debido al uso de una venta rectangular (ventana más simple) y se usa las variaciones de *Hamming* y *Hanning*, y nuevamente asumen que la señal en el espacio de la ventana es estacionaria y periódica, este análisis se ha realizado por años permitiendo realizar análisis válidos, sin embargo, en muchos casos son aproximaciones que dejan de ser válidas cuando las señales presentan características No estacionarias y mucho menos periódicas, por tanto en cada implementación del método habría que correr nuevamente todo al algoritmo, siendo esto un problema, no solo computacional, sino también metodológico. Los modelos adaptativos brindan una posibilidad de incluir dentro de un modelo características dinámicas de las señales que presentan comportamiento No estacionarios y además tampoco presentan periodicidad, y poder realizar una representación de los fenómenos mucho más apropiada que una técnica convencional guardando un grado de memoria debido a proceso de adaptación [38].

4.6. Clasificación

Es un proceso de estimación matemático que tiene como objetivo encontrar un modelo matemático que permita separar o identificar una entidad en particular utilizando un conjunto de ejemplos o información suministrada. El proceso de clasificación se puede realizar utilizando clasificación supervisada, clasificación no supervisada, aprendizaje por esfuerzo, transducción o aprendizaje multi-tarea. Algunos de los clasificadores más comunes en este tipo de tareas son: los vecinos más cercanos (KNN), las máquinas de vectores de soporte (SVM), los modelos ocultos de Markov (HMM), las redes neuronales artificiales (RNA), clasificador Bayesiano, entre otros [56].

4.7. Clasificación no supervisada

Son metodologías de agrupamiento que tienen como objetivo asignar una etiqueta a una observación, ajustando las fronteras entre las diferentes clases a identificar. Se distingue de la clasificación supervisada, porque no hay un conocimiento a priori del comportamiento de las observaciones. En síntesis su objetivo, es agrupar entidades que pertenezcan a un mismo conjunto.

4.8. Clasificación supervisada

Son técnicas de aprendizaje que parten de un conocimiento a priori sobre el comportamiento de la observación a ser etiquetada. Estas técnicas en general buscan la estimación de los parámetros de un hiperplano de separación que permita establecer un límite entre las etiquetas asignar.

4.9. Análisis de rendimiento de un clasificador

El rendimiento de un clasificador, se define como un indicador de la capacidad de etiquetar una observación correctamente. Estos indicadores se definen como [56]:

4.10. Matriz de confusión

Las matrices de confusión fueron propuestas por Kohavi y Provost en 1998, estas contiene información sobre el desempeño de un sistema de clasificación donde se relacionan las etiquetas de un conjunto de datos y posteriormente el resultado de la clasificación.

Verdaderos Positivos (v_p): Se definen como los ejemplos que pertenecen a la clase y el clasificador estimó que pertenecen a esa clase.

Verdadero Negativos (v_n): Se definen como los ejemplos que no pertenecen a la clase y el clasificador estimó que no pertenecen a esa clase.

Falsos Negativos (f_n): Son los casos que el clasificador no los clasificó en la clase a la que eran pertenecientes.

Falsos Positivos (f_p): Son los casos que el clasificador los clasificó en una clase a la que no eran pertenecientes.

$$\begin{bmatrix} V_p & f_p \\ f_n & V_n \end{bmatrix} \quad (17)$$

A partir de los parámetros de la matriz de confusión se puede definir los conceptos de especificidad y sensibilidad así:

Especificidad: Es el cociente entre el número de observaciones positivas incorrectamente clasificadas y el número total de observaciones. Este parámetro se puede calcular como:

$$Especificidad = \frac{f_n}{v_p + f_n} \quad (18)$$

Sensibilidad: Cociente entre el número de observaciones positivas correctamente clasificados y el número total de observaciones. Este parámetro se puede calcular como:

$$Sensibilidad = \frac{v_p}{v_p + f_n} \quad (19)$$

La precisión determinada puede no ser una medida de rendimiento adecuada cuando el número de casos negativos es mucho mayor que el número de casos positivos (Kubat et al., 1998). Supongamos que hay 1000 casos, 995 de los cuales son casos negativos y 5 casos positivos. Si el sistema los clasifica a todos como negativos, la precisión sería del 99.5 %, a pesar de que el clasificador no detectó todos los casos positivos.

5. METODOLOGÍA

Para el desarrollo de la estructura de reconocimiento de la actividad física, se propuso un método basado en movimientos primitivos, estos a su vez se inspiran en la similitud de las señales de voz humana con el movimiento humano [57]. En el reconocimiento de voz, las frases se dividen en palabras aisladas o fonemas generando una secuencia o codificación de cada frase; lo que permite construir un modelo de clasificación de N fonemas compartidos para el conjunto de palabras a reconocer. Estos modelos se utilizan como los bloques básicos para construir palabras y frases de una manera jerárquica [58]. Continuando con la idea propuesta, cada actividad se representa como una secuencia de sub-movimientos generando un código único que permite obtener un factor discriminante en la clasificación de actividad.

La metodología implementada en el identificación de actividades físicas se puede ampliar en el trabajo propuesto por Calvo y Holguín en [8] para observar un enfoque de aprendizaje supervisado, y en el trabajo de Calvo y Morales en [31] para un enfoque no supervisado. Fundamentalmente, el proceso de reconocimiento consta de dos etapas, (ver figura 1):

1. Reconocimiento de movimientos primitivos

- a) Señales sensores (Kinect, IMU, EMG)

- 1) Extracción de características

- b) Codificación de movimientos primitivos

2. Reconocimiento de actividades

- a) fusión de etiquetas de movimientos primitivos

- b) Clasificación de movimientos

El presente trabajo se enfoca en la implementación de descriptores sobre las señales de electromiografía (EMG) para el mejoramiento en el desempeño del reconocimiento de actividades físicas.

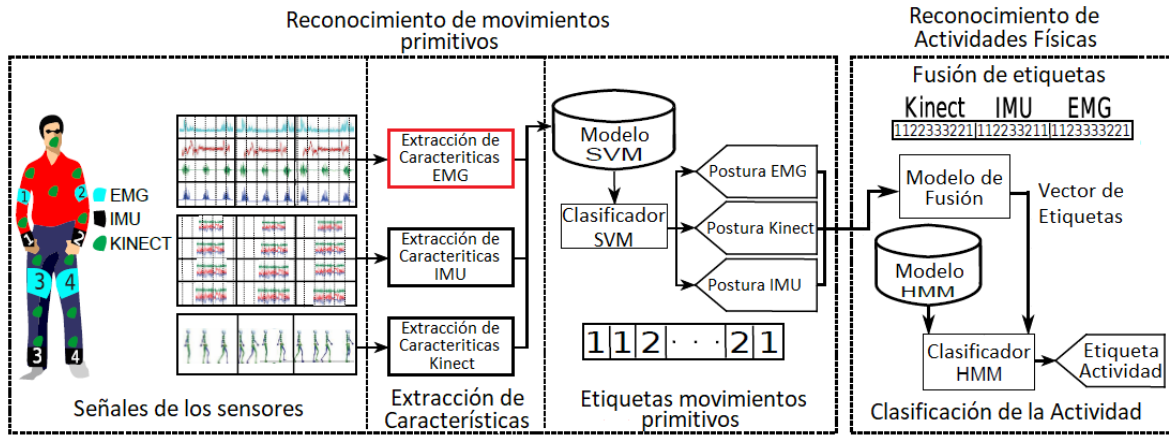


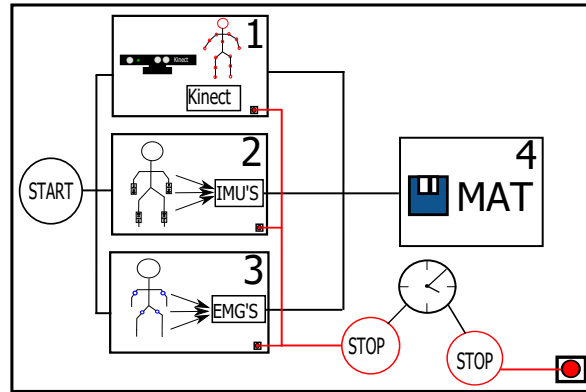
Figura 1. Metodología de identificación de actividades físicas

5.1. Adquisición y etiquetado de la de datos

La finalidad del desarrollo de este trabajo no es la de implementar el hardware y software de captura de datos, para el desarrollo de este trabajo se uso la base de datos propuesta por Calvo y Holguín en [8], para mayor detalle sobre la implementación de la captura de datos es posible ampliar esta información desde el trabajo. Básicamente, el sistema fue diseñado en Labview y se puede observar en la figura 2, donde se evidencian cuatro etapas fundamentales para el registro sincronizado de estas señales; estas etapas constan de:

1. La captura sincronizada de la red de sensores IMU.
2. La captura sincronizada de la red de sensores EMG.
3. La captura de los puntos articulados del cuerpo utilizando el Skeleton Tracking provisto por el Kinect.
4. El almacenamiento de los datos en la estructura binaria *.mat* utilizada por entornos como Matlab y Octave para el almacenamiento de datos.

Figura 2. Etapas del sistema de captura sincronizado



La extracción de características se implementará sobre la identificación de movimientos primitivos y este conjunto de movimientos primitivos definidos para la identificación de actividades físicas, o también denominado como vocabulario o diccionario, permite describir el conjunto de sub-movimientos que son comunes para el conjunto total de actividades. La codificación de los movimientos primitivos se puede observar en la tabla 1,

La base datos anotada propuesta por Calvo y Holguín en [8] se implemento a partir de la instrumentación de 16 voluntarios, los cuales ejecutaron 3 veces las actividades de la tabla 1. En la ejecución de estas acciones se logró almacenar un total de 48 ejemplos por clase. Las señales capturadas son almacenadas en archivos con extensión *.mat* y agrupadas de acuerdo a la actividad ejecutada. Las orientaciones de los sensores y distribución espacial de cada red en el cuerpo fueron cuidadosamente organizados en cada individuo con el fin de garantizar las misma configuración en todos los ejemplos almacenados.

Tabla 1. Lista de actividades

Actividad	Etiqueta
Quedarse quieto	1
Agacharse y levantarse	2
Saltar	3
Levantar mano derecha	4
Trotar	5

Tabla 2. Etiquetas del SVM para cada postura

Sub-actividad	Etiqueta	Sub-actividad	Etiqueta
Reposo	1	Mano levantada a $1/4$	5
Medio Agachado	2	Mano levantada a $3/4$	6
Totalmente agachado	3	Paso adelante pie derecho	7
Suspendido en el aire $1/4$	4	Paso adelante pie izquierdo	8

5.2. Conjunto de sensores multimodales

El proceso de extracción de características propuesto por Calvo y Holguín en [8] para el conjunto de sensores multimodales se divide en tres módulos fundamentales, que son:

1. Extracción de características del Kinect,
2. Extracción de características para la red sensores IMU
3. Extracción de características para la red de sensores EMG

En esta etapa el desarrollo del trabajo se centrará en los métodos de extracción de características únicamente sobre la señal de los sensores EMG por tanto, en la siguiente sección se describirá el proceso de extracción, como los métodos y modelos computacionales aplicados al modulo EMG.

5.3. Metodología de construcción de descriptores y experimentos

La captura de las señales EMG se realizó con 4 sensores, uno en cada extremidad como está dispuesto en la imagen lo que permite manejar la información de cada sensor de manera independiente, por tal motivo, dentro del desarrollo de la experimentación se probaron todos los descriptores por separado en cada una de las señales de los sensores y luego se concatenaron sus características construyendo un solo vector descriptor por cada movimiento primitivo, y se realizó la misma implementación de los descriptores concatenando las señales de los sensores




Figura 3. Disposición de los sensores IMU y EMG sobre el sujeto de prueba

en una sola, esto ultimo con la finalidad de probar el desempeño de las metodologías basadas en la transformada de Fourier que presenta problemas con señales no estacionarias, e identificar descriptores robustos a ello.

El desarrollo de este trabajo evalúa el mejoramiento el desempeño en la detección con sensores EMG para la fusión de sensores multimodales, por lo que para cada combinación de descriptores usando las señales una a una y concatenadas, se evaluó el desempeño de ellos en la fusión multimodal con la realización de los siguientes experimentos:

- EXPERIMENTO E: Detección de movimiento solo con el uso de los sensores EMG.
- EXPERIMENTO EK: Detección de movimiento fusionando la información EMG y los puntos de articulación KINECT.
- EXPERIMENTO IE: Detección de movimiento fusionando la información de los sensores EMG y los sensores de masa inercial IMU.
- EXPERIMENTO IEK: Detección de movimiento fusionando la información de los sensores EMG, los sensores de masa inercial IMU y los puntos de articulación KINECT.

A continuación, se hace una relación los descriptores construidos para el desarrollo del presente trabajo.

5.4. Transformada rápida de Fourier (FFT)

La transformada de Fourier es uno modelos de transformación del dominio del tiempo al dominio de la frecuencia, y este se puede ver como un modelo de proyección ortogonal sobre un espacio completo de funciones ortogonales sinusoidales armónicas. En el análisis de señales es ampliamente usado por la relación inteligible de su conjunto de señales, es decir, a partir de esta información de amplitud, frecuencia y fase es posible identificar y caracterizar una señal arbitraria no analítica.

Para el uso de este método de transformación se usa es espectro del proceso de transformación, con este se construye un vector de datos el cual es usado como vector de características y posteriormente usado en el Sistema de clasificación.

$$X_n = \sum_{n=0}^{N-1} x_n e^{-\frac{2\pi i}{N} kn} \quad (20)$$

Donde $k = 0, 1, \dots, N - 1$

5.5. Coeficientes Auto regresivos (AR)

Para el desarrollo de este descriptor, se asume que se cuenta con un conjunto de puntos que podrían denominarse como una serie de tiempo, así: $u(n), u(n - 1), \dots, u(n - M)$, representa la realización de un modelo autor-regresivo (AR) de orden M , si este satisface la ecuación en diferencias presentada en la ecuación 21.

$$u(n) + a_1^* u(n - 1) + a_M^* u(n - M) = v(n) \quad (21)$$

Donde a_1, a_2, \dots, a_M son contantes llamadas *los parámetros AR*, y $\{v(n)\}$ es el ruido blanco del proceso. Los términos $a_k^* u(n - k)$ es el producto interno de a_k y $u(n - k)$, donde $k = 1, 2, \dots, M$.

El vector de características se obtiene a partir de la implementación del algoritmo del modelo

autor-regresivo y la concatenación de los coeficientes a_1, a_2, \dots, a_M , dentro de un modelo autor-regresivo de orden 10.

5.6. Transformada Wavelet

Como se menciona en el estado del arte, la transformada Wavelet es uno de los métodos matemáticos más ampliamente usados en el análisis de señales, en incluso el estado del arte lo presenta ampliamente en el análisis de señales EMG debido a las características NO estacionarias y a la capacidad que representa características en modelos de tiempo frecuencia. En el trabajo presentado por Calvo y Holguín [8], el único método de descripción usado sobre las señales EMG fue una transformada Wavelet discreta tipo haar de 20 niveles (para más detalles ver [8]).

Del análisis del estado del arte se identificó la combinación de múltiples métodos que potencian la capacidad de clasificación de la transformada wavelet, en este trabajo se implementaron las siguientes metodologías combinadas con la transformada Wavelet.

5.6.1. Coeficientes Wavelet de Aproximación y Detalle

De la implementación de un Wavelet discreta, se obtiene un conjunto de datos de una señal $x(t)$ que son cA y cD , coeficientes de aproximación y coeficientes de detalle respectivamente. Como se observa en la figura 4, el vector c contiene los coeficientes de aproximación y detalle, los cuales son usados como descriptor en el sistema de identificación.

5.6.2. Descomposición modal Wavelet

En la revisión del estado del arte, se identificó que la transformada Wavelet también se puede observar como un método de descomposición modal, es decir que, es posible descomponer una señal en señales más simples y con unas características definidas a partir del uso de la señal madre, con la cual se podría ver como un muestreo suave sobre cada delta de tiempo y esto




Figura 4. Descomposición Wavelet de una señal en coeficientes de detalle y aproximación (Imagen Obtenida de Mathworks-MATLAB)

permite ver cada conjunto de coeficientes de detalle como una señal y aplicar metodologías, las que se aplicaron en este trabajo son:

- Transformada discreta de Fourier (DFT): Se aplica la transformada rápida de Fourier como se mostró en la sección 5.4.
- Coeficientes de modelos Autor-regresivos (AR): se aplica sobre la descomposición modela wavelet (6)
- Momentos Estadísticos (ME): Se construyo un vector con los siguientes momentos estadísticos: [promedio, media, moda, varianza, sesgo, curtosis]
- Momentos Estadísticos y de Energía (MEE): [promedio, media, moda, varianza, sesgo, curtosis, potencia, entropía, valor rms, suma total, varianza cuadrática, densidad espectral, promedio espectral, Vrms espectral, derivada promedio, promedio logaritmo espectral]

Para cada una de las metodologías mostradas anteriormente, se realizaron los siguientes pasos:

Algoritmo 1 Técnicas sobre descomposición modal Wavelet

Paso_1 Aplicar transformada Wavelet a la señal

Paso_2 Definir vector vacío Características

Paso_3 Para Nivel =1 hasta nivel N haga

Var_aux = método_de_caracterización(descomposición(Nivel))

Características = [Características Var_aux];

Paso_4 Salida Características

Donde la función *método_de_caracterización* mostrada en el Paso_3 del algoritmo (1) es uno de los métodos mostrados anteriormente denominados como DFT, AR, ME ó MEE.

5.7. Clasificación de Movimientos

Para esta etapa se utilizaron tres máquinas de vectores de soporte multiclase con estrategia de clasificación “*All-pairs*”; este método de aprendizaje utiliza un kernel gaussiano con radio 1×10^4 para el Kinect®. Este proceso se repite con los datos de los sensores IMU y con la información de los sensores EMG.

6. RECONOCIMIENTO DE ACTIVIDAD

El proceso de reconocimiento de actividad consiste en la clasificación de las actividades establecidas en la tabla 1, utilizando las secuencias generadas en la etapa 5. Se presenta una parte sobre el modelo de fusión de datos multimodales y la implementación de un Modelo Oculto de Markov (HMM) que se encarga de la identificación de las secuencias de los movimientos primitivos y finalmente de identificar la secuencia entregada e identificar la actividad asociada, esto se puede observar en la figura 1 y para ampliar esta información sobre el método de implementación del sistema de reconocimiento vea el documento de Calvo y Holguín [8].

El proceso de clasificación parte de un modelo entrenado que proporciona una separación entre cada clase. Este modelo permite asignar una etiqueta de pertenencia evaluando dicho modelo. El entrenamiento de los modelos SVM se realiza utilizando un kernel gaussiano y una estrategia de clasificación multiclase “*All-pairs*”.

Para realizar el procedimiento de evaluación del modelo entrenado se utilizó una estrategia de validación cruzada, fraccionando la base de datos con el 70% para el entrenamiento y 30% para evaluación; este proceso realiza iteraciones de Montecarlo con criterio de paro $\|\text{diag}(M_k) - \text{diag}(M_{k-1})\| < 0,001$, donde $\text{diag}(M_k)$ es el vector generado por la diagonal de la matriz de confusión y k es la iteración promedio actual de Montecarlo.

Este procedimiento de Montecarlo, separa de forma aleatoria los datos de entrenamiento y los datos, permitiendo en cada iteración obtener modelos con diferentes datos y observar el comportamiento en la clasificación de actividad. Las estadísticas obtenidas en el experimento consisten en el cálculo de la matriz de confusión y el comportamiento promedio del porcentaje de acierto para cada clasificador aplicado. Para entrenar las SVM se utilizó la base de datos anotada explicada ampliamente en el documento de Calvo y Holguín [8].

7. EXPERIMENTOS Y RESULTADOS

En esta etapa, se presentan los resultados obtenidos al validar el desempeño de los vectores de características propuestos para de la clasificación de actividad y movimientos primitivos aplicando Montecarlo para la estimación del error. Para lograr una comparación sobre el desempeño del clasificador con los vectores de características construidos se realizara una comparación con los resultados obtenidos en el trabajo de Calvo y Holguín.

como se observa en la figura 3, y como se explicó en la sección 5.3, se cuenta con un conjunto de 4 señales que fueron trabajadas individualmente, y concatenando las 4 señales, se construyeron un total de 8 descriptores, y se compararon los experimentos propuestos por Calvo y Holguín que estaban relacionados con las señales EMG, y los experimentos propuestos son:

- *Experimento E*: Detección de movimiento solo con el uso de los sensores EMG.
- *Experimento EK*: Detección de movimiento fusionando la información EMG y los puntos de articulación KINECT.
- *Experimento IE*: Detección de movimiento fisionando la información de los sensores EMG y los sensores de masa inercial IMU.
- *Experimento IEK*: Detección de movimiento fisionando la información de los sensores EMG, los sensores de masa inercial IMU y los puntos de articulación KINECT.

Debido a la gran cantidad de experimentos realizados (64 experimentos), se extendería ampliamente el análisis de resultados, por tal motivo, solo se presentaran diagonales principales de las matrices de confusión, y en los anexos se incluirán las matrices de confusión de todos los experimentos realizados.

Los índices de descriptores para identificar la metodología de cada experimento para la identificación de movimientos primitivos tiene la siguiente construcción [*señal, metodo*].

1. SIGFFT: Señales EMG independientes con la aplicación de DFT individual y concatenación de espectros.

2. CATFFT: Señales EMG concatenadas con la aplicación de DFT a la señal concatenada, el vector de características es el espectro de la señal concatenada.
3. SIGAR: Señales EMG independientes con la aplicación de AR individual y concatenación de coeficientes.
4. CATAR: Señales EMG concatenadas con la aplicación de AR a la señal concatenada, el vector de características es el conjunto de coeficientes de la señal concatenada.
5. SIGWAV: Señales EMG independientes con la aplicación de DWT individual y concatenación de coeficientes de detalle y aproximación.
6. CATWAV: Señales EMG concatenadas con la aplicación de DWT a la señal concatenada, el vector de características es el conjunto de coeficientes de aproximación y detalle de la señal concatenada.
7. SIGWAVC: Señales EMG independientes con la aplicación de DWT individual y concatenación de coeficientes de detalle y aproximación de orden superior.
8. CATWAVC: Señales EMG concatenadas con la aplicación de DWT a la señal concatenada, el vector de características es el conjunto de coeficientes de aproximación y detalle de orden superior de la señal concatenada.
9. SIGWAVDEC_DFT: Señales EMG independientes con la aplicación de DWT como descomposición modal aplicando DFT a cada nivel de descomposición y concatenando los espectros
10. CATWAVDEC_DFT: Señales EMG concatenadas con la aplicación de DWT como descomposición modal aplicando DFT a las señales concatenadas
11. SIGWAVDEC_AR: Señales EMG independientes con la aplicación de DWT como descomposición modal aplicando AR a cada nivel de descomposición y concatenando los espectros

12. CATWAVDEC_AR: Señales EMG concatenadas con la aplicación de DWT como descomposición modal aplicando AR a las señales concatenadas
13. SIGWAVDEC_EST: Señales EMG independientes con la aplicación de DWT como descomposición modal aplicando MOMENTOS ESTADÍSTICOS a cada nivel de descomposición y concatenando los espectros
14. CATWAVDEC_EST: Señales EMG concatenadas con la aplicación de DWT como descomposición modal aplicando MOMENTOS ESTADÍSTICOS a las señales concatenadas
15. SIGWAVDEC_EE: Señales EMG independientes con la aplicación de DWT como descomposición modal aplicando MOMENTOS ESTADÍSTICOS Y DE ENERGÍA a cada nivel de descomposición y concatenando los espectros
16. CATWAVDEC_EE: Señales EMG concatenadas con la aplicación de DWT como descomposición modal aplicando MOMENTOS ESTADÍSTICOS Y DE ENERGÍA a las señales concatenadas
17. CyH: Resultados del experimento reportado por Calvo y Holguín en el documento [8].

7.1. Reconocimiento de Movimientos Primitivos

Posterior a la realización de la experimentación con los descriptores desarrollados, se realizó un proceso de promediar los desempeños de identificación de cada movimiento primitivo, el promedio presentado por Calvo y Holguín en [8] del descriptor usado para las señales EMG (denominado en la tabla 3 como CyH) usando todos los sensores fue de $61,13 \pm 13,14 \%$, como se puede observar en la tabla 3. En los resultados presentados se evidencia que el clasificador de movimientos primitivos presenta una dificultad en la identificación del movimiento primitivo C8, aspecto de baja el promedio y aumenta la desviación del descriptor.

Tabla 3. Diagonales de las Matrices de confusión

Clases	CyH	SIGWAVDEC_EE	SIGWAVDEC_EST	SIGWAVC
C1	72.28±5.83	75.87 ± 6.83	74.99 ± 7.87	72.89 ± 6.38
C2	66.51±1.13	68.82 ± 1.94	67.88 ± 2.07	65.17 ± 2.19
C3	70.84±4.73	71.02 ± 4.96	69.48 ± 5.46	70.50 ± 5.52
C4	71.49±1.33	71.51 ± 1.48	73.10 ± 1.37	68.34 ± 1.26
C5	59.43±5.21	58.92 ± 5.30	56.12 ± 4.01	55.14 ± 3.8
C6	63.88±2.35	65.82 ± 2.23	64.12 ± 2.34	60.80 ± 2.60
C7	50.54±1.84	57.04 ± 1.86	55.12 ± 2.03	54.48 ± 1.92
C8	34.08±2.50	56.15 ± 2.65	54.30 ± 3.21	52.50 ± 2.69
Promedio	61.13±13.14	65.64 ± 7.44	64.39 ± 8.30	62.48 ± 7.88

En la Tabla 3 se relacionaron 3 de los descriptores con mejor desempeño dentro del mismo proceso, los 3 clasificadores presentaron desempeños superiores a los reportados con el descriptor CyH, con una desviación estándar mucho menor, por tanto se evidencia que logra mejorar el proceso de clasificación de movimientos primitivos. Observando los Anexos del documento es posible analizar los resultados de todos los descriptores implementados y aunque todos mejoran el porcentaje presentado por CyH, solo 9 de ellos aumentan el porcentaje de clasificación por encima del 50 %.

Cabe anotar que los 3 descriptores que mejoraron el desempeño presentado por CyH están basados en métodos con transformada Wavelet, y el mejor usa la transformada Wavelet como un método de descomposición modal y construir descriptores usando métodos estadísticos, energía de señal y densidad espectral.

7.2. Reconocimiento de actividades físicas

Como se a venido viendo a lo largo del documento, el proceso de identificación de actividades físicas consta de varias etapas de clasificación, la primera etapa esta basada en maquinas de soporte vectorial (SVM) con la que se identifican los movimientos primitivos (o las palabras de una frase, según la analogía con el lenguaje), posteriormente sigue un sistema de identificación de secuencias de movimientos primitivos con los cuales se busca identificar una actividad física, en este proceso es donde entra la implementación de fusión de datos multimodales. Para ello,

se presentaron experimentos con combinaciones de sensores para evaluar el desempeño de los descriptores, al inicio de la sección 7 se relacionaron las combinaciones de sensores que se evaluaron, a continuación los resultados obtenidos.

7.2.1. Experimento EMG

En la tabla 1, se relacionan las 5 actividades físicas que se busca identificar, en la tabla 4 se muestran los resultados de las diagonales de las matrices de confusión de los experimento realizados usando unicamente las señales EMG. Para este caso se evaluaron nuevamente los 16 métodos de caracterización de las señales EMG. En esta ocasión ninguno de los descriptores mejoro el desempeño presentado por CyH, sin embargo, se puede observar que al igual que en los movimientos primitivos, los resultados presentados por CyH presentan dificultades en la clasificación del movimiento 1 (Estar quieto).

Tabla 4. Matriz de Confusión EMG con todos los sensores

Actividad	CyH	SIGWAVDEC_EST	CATWAVDEC_EE	SIGWAVDEC_EE	SIGWAVDEC_AR
1	38.78±8.12	60.88±15.28	71.00±16.34	72.72±13.90	60.59±20.03
2	90.94±4.81	71.73±11.54	65.38±11.74	69.59±12.9	71.71±12.79
3	96.16±3.21	90.62±7.53	81.24±9.63	72.19±11.85	86.33±7.86
4	94.08±3.94	82.76±11.75	86.42±11.92	90.45±10.45	82.34±9.87
5	89.69±5.07	91.09±9.4	89.43±10.81	84.16±8.38	87.02±8.78
Promedio	81.93±24.26	79.42±13.00	78.69±10.22	77.82±9.02	77.60±11.3

Con los resultados obtenidos, aunque ninguno de los descriptores propuestos mejoró el desempeño del reportado por CyH, si se evidencia que hay un aumento significativo en los porcentajes de identificación de la actividad 1, es decir, los 4 descriptores con mejor desempeño aumentan la capacidad de identificación y disminuyen la desviación estándar. En este nuevo experimento, el descriptor que presento mejor desempeño con los movimientos primitivos (*SIGWAVDEC_EE*) aun esta dentro de los 4 mejores, y se evidencia que los descriptores aplicados sobre las señales individuales presentan mejores resultados.

7.2.2. Experimento EMG+Kinect®

Este experimento fusiona los datos de las señales EMG y Kinect®, en la Tabla 5 se puede identificar las diagonales de las matrices de confusión del experimento reportado por CyH en [8], y así como los resultados de los 4 mejores desempeños de los métodos de caracterización propuestos.

Tabla 5. Matriz de Confusión EMG+Kinect®

Actividad	CyH	CATAR	SIGWAVC	SIGWAVDEC_EST	CATWAVC
1	91.00±4.78	86.50±10.50	97.12±4.37	85.99±13.24	89.37±8.48
2	100.00±0.00	90.67±11.19	81.30±10.81	88.28±7.5	85.33±6.88
3	98.80±1.82	97.50±4.21	94.85±5.04	99.14±2.29	100.00±0.00
4	96.68±2.51	94.46±7.75	95.93±5.51	92.49±6.26	90.54±8.05
5	96.81±2.93	99.44±1.74	95.49±4.8	98.62±2.90	98.42±3.8
Promedio	96.60±3.54	93.71±5.22	92.94±6.56	92.90±5.94	92.73±6.2

Observando los resultados presentados en la tabla 5, nuevamente ninguno de los descriptores mejora el desempeño reportado por CyH, sin embargo se observa que los resultados obtenidos son muy homogéneos en cuanto a la media del desempeño en la clasificación y la desviación estándar. Para este experimento, el que presento mejor desempeño fue el descritos basado en la concatenación de las señales EMG y la aplicación de un descriptor basado en modelos auto-regresivos, pero se identifica nuevamente que los descriptores basados en Wavelet presentan desempeños comparables.

7.2.3. Experimento EMG+IMU

El experimento de la fusión de los datos de las señales EMG y las unidades de masa inercial IMU presenta resultados similares al experimento $EMG + KI$, los resultados presentados por el descriptor CyH presenta un desempeño superior a las 4 mejores desempeños de los descriptores propuestos, sin embargo los resultado obtenidos son comparables, pues se puede observar en la tabla 6 que los descriptores propuestos presentan desempeños por encima del 90 % con desviaciones estándar reducidas.

Tabla 6. Matriz de Confusión EMG+IMU

Actividad	CyH	SIGWAVDEC_EST	SIGWAVC	SIGWAVDEC_EE	CATWAVDEC_EST
1	100.00±0.00	89.04±10.86	93.74±8.31	88.75±10.44	86.49±12.36
2	98.14±0.02	86.45±8.40	82.79±10.97	89.64±8.72	86.91±10.04
3	99.46±1.23	98.15±2.83	96.66±5.90	94.83±5.88	98.44±4.08
4	99.67±0.96	98.39±3.40	96.24±5.75	97.09±5.78	93.56±8.36
5	96.65±3.00	100.00±0.00	98.91±3.45	95.76±5.10	98.20±4.1
Promedio	98.78±1.38	94.41±6.19	93.67±6.35	93.21±3.77	92.72±5.8

Como se ha observado en los resultados presentados hasta el momento, los métodos de caracterización basados en métodos de transformada Wavelet presentan los mejores desempeños, el descriptor SIGWAVDEC_EE sigue estando entre los mejores desempeños y comparable con los resultados obtenidos por el descriptor CyH.

7.2.4. Experimento EMG+Kinect®+IMU

En la tabla 7 se presentan los resultados obtenidos en el experimento basado en la fusión multimodal de los sensores EMG, Kinect® y IMU comparados con el obtenido por el descriptor CyH. Para este experimento se puede identificar que un descriptor mejora el desempeño del reportado por CyH aumentando el promedio y disminuyendo la desviación significativamente, aspecto que no solo mejora un poco el desempeño sino que aumenta la precisión del clasificador.

Tabla 7. Matriz de Confusión EMG+Kinect®+IMU

Actividad	CyH	CATAR	CATWAVDEC_EE	CATWAVDEC_AR	CATWAV
1	100.00±0.00	97.87±3.93	97.79±4.18	92.27±7.63	95.61±3.15
2	99.60±1.53	98.55±2.61	93.76±6.45	96.86±5.60	91.00±10.32
3	99.62±1.03	99.00±2.46	100.00±0.00	99.77±1.35	100.00±0.00
4	99.09±1.59	99.04±2.36	96.94±6.60	95.74±5.7	94.82±7.5
5	95.76±3.36	100.00±0.00	100.00±0.00	98.74±2.66	99.48±1.73
Promedio	98.81±1.74	98.89±0.78	97.70±2.58	96.68±2.92	96.18±3.69

Con los resultado presentado en la tabla 7, se puede evidenciar que los 4 mejores descriptores presentan desempeños de clasificación superiores al 95 % con desviaciones inferiores al 4 %,

aspecto evidencia que los descriptores implementados para las señales EMG no solo presentan buenos resultados sino que mejoran la precisión de los clasificadores. En el experimento de la fusión de datos multimodal de los 3 sensores propuestos por Calvo y Holguín en [8] y observando la tabla 7 se identifica que en este caso, los métodos aplicados sobre la concatenación de las señales EMG presentaron los mejores resultados, así como la aplicación del descriptor basado en coeficientes autorregresivos, y de igual manera se evidencia que los resultados obtenidos con los descriptores basados en la transformada Wavelet siguen presentando los mejores resultados.

7.2.5. Comparación de los desempeños de clasificación en la fusión de datos multimodal

A continuación en la tabla se muestran los resultados de los promedio de clasificación de todos los descriptores implementados en comparación con CyH ordenados de mayor a menor desempeño, como resumen de los resultados presentados anteriormente.

Tabla 8. Tabla de comparación descriptores implementados en los experimentos EMG y EMG+Kinect®

Puesto	EMG		EMG+Kinect	
	CyH	81.93±24.26	CyH	96.60±3.54
1	SIGWAVDEC_EST	79.42±13.00	CATAR	93.71±5.22
2	CATWAVDEC_EE	78.69±10.22	SIGWAVC	92.94±6.56
3	SIGWAVDEC_EE	77.82±9.02	SIGWAVDEC_EST	92.90±5.94
4	SIGWAVDEC_AR	77.60±11.31	CATWAVC	92.73±6.25
5	SIGWAVC	76.22±7.35	SIGWAVDEC_EE	92.55±5.1
6	SIGAR	75.67±16.85	SIGAR	92.51±5.04
7	CATWAVDEC_AR	74.96±18.20	CATWAVDEC_EST	92.49±8.16
8	SIGFFT	74.68±9.84	CATFFT	92.42±4.38
9	CATWAVDEC_DFT	73.34±10.19	CATWAVDEC_DFT	92.33±6.69
10	CATWAVDEC_EST	72.71±13.26	SIGWAVDEC_AR	91.35±8.13
11	CATFFT	71.09±14.96	CATWAVDEC_AR	91.10±10.50
12	CATWAVC	70.79±14.83	SIGWAVDEC_DFT	90.79±8.85
13	CATAR	67.79±16.66	CATWAVDEC_EE	90.61±6.12
14	SIGWAV	67.68±8.28	CATWAV	89.68±6.04
15	SIGWAVDEC_DFT	67.11±17.95	SIGWAV	88.45±8.47
16	CATWAV	65.20±7.50	SIGFFT	88.43±9.32

Tabla 9. Tabla de comparación descriptores implementados en los experimentos EMG+IMU y EMG+Kinect®+IMU

Puesto	EMG+IMU		EMG+Kinect+IMU	
	CyH	98.78±1.38	CyH	98.81±1.74
1	SIGWAVDEC_EST	94.41±6.19	CATAR	98.89±0.78
2	SIGWAVC	93.67±6.35	CATWAVDEC_EE	7.70±2.58
3	SIGWAVDEC_EE	93.21±3.77	CATWAVDEC_AR	96.68±2.92
4	CATWAVDEC_EST	92.72±5.83	CATWAV	96.18±3.69
5	CATWAVDEC_EE	92.55±7.59	CATWAVC	96.09±4.82
6	CATFFT	91.88±5.91	SIGWAVDEC_EST	96.02±3.10
7	SIGFFT	91.81±5.53	SIGWAVC	95.84±3.89
8	CATWAVDEC_DFT	91.45±8.69	CATWAVDEC_EST	95.63±4.38
9	CATWAVDEC_AR	91.33±8.09	SIGWAVDEC_EE	95.46±3.60
10	CATWAV	91.11±2.83	SIGAR	95.28±5.06
11	SIGAR	91.00±9.26	CATFFT	95.24±4.53
12	SIGWAVDEC_DFT	90.75±3.90	CATWAVDEC_DFT	95.01±4.99
13	CATAR	90.00±13.00	SIGWAVDEC_AR	94.95±4.39
14	CATWAVC	88.98±12.46	SIGWAVDEC_DFT	94.49±4.45
15	SIGWAVDEC_AR	88.58±10.10	SIGFFT	94.09±8.17
16	SIGWAV	87.50±10.02	SIGWAV	93.96±4.90

8. CONCLUSIONES Y RECOMENDACIONES

8.1. CONCLUSIONES

Con el desarrollo de este trabajo se logro implementar un conjunto de descriptores que apoyan el mejoramiento del desempeño en la clasificación de actividades físicas. Los resultados presentados por Calvo y Holguín en [8] se encuentran dentro de los valores reportados en el estado del arte con porcentajes de clasificación superiores al 95 %. En el presente trabajo fue posible aumentar el desempeño de los resultados de los experimentos propuestos por Calvo y Holguín desarrollando nuevos descriptores sobre las señales EMG.

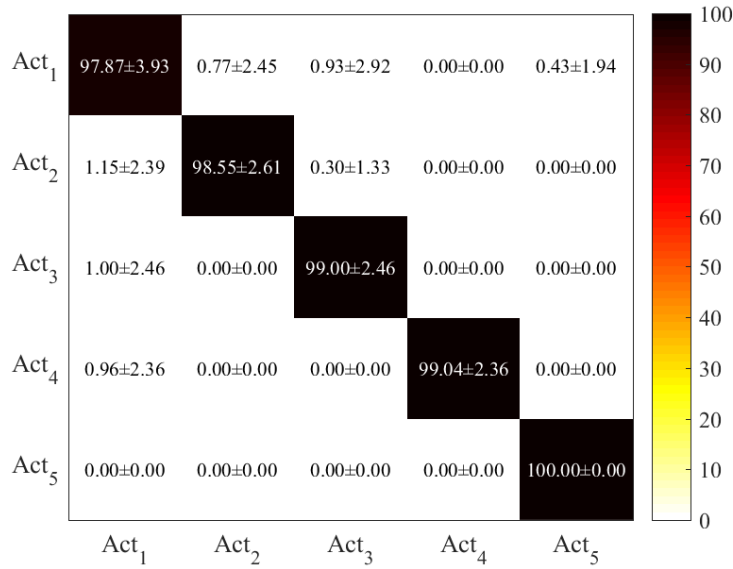
Como se comento anteriormente, se observa que la implementación de la clasificación de movimientos primitivos propuesta por Calvo y Holguín presenta una dificultad para la clasificación de los movimientos primitivos 7 y 8 especialmente, esto se puede evidenciar por los resultados presentados en la tabla 3, y aunque los descriptores presentados mejoraron el desempeño del descriptor CyH, si se observan las matrices de confusión del anexo (Ver sección 9.1), debido a la intensidad de color permite identificar que es una dificultad marcada que no depende del descriptor, sino, de la naturaleza de los datos; desde el estado del arte se evidencia que el manejo de las señales EMG tienen un alto grado de complejidad debido a que presentan una alta dependencia de su localización en el individuo [17], las combinación de músculos para el desarrollo de una actividad, la cantidad limitada de sensores [23, 38] y contando con que las señales EMG son no estacionarias lo cual dificulta el tratamiento de las mismas y hace necesario incluir nuevas técnicas como las presentadas en este trabajo.

Como se evidencio en el estado del arte, los descriptores basados en la transformada Wavelet han presentado los mejores resultados en la caracterización de señales EMG [29, 44, 30, 16, 9, 17, 23, 24, 4, 35, 43, 25, 26]. En este trabajo se incluyo la experimentación con las transformada Wavelet y se propuso la implementación de descriptores usando la transformada Wavelet como un método de descomposición modal des señales y aplicando múltiples técnicas sobre los modos descompuestos obteniendo resultado que mejoran el desempeño del los clasificadores de movimientos primitivos con un $60,88 \pm 15,28$ vs $38,78 \pm 8,12$ % presentado por Calvo Y

Holguín.

En la implementación del Clasificador HMM para la identificación de secuencia de movimientos primitivos e identificar actividades físicas se obtuvieron resultados aceptables, donde los descriptores propuestos superaron los resultados comparados en el experimento donde se fusionan los 3 tipos de sensores multimodales donde se mantuvo un porcentaje de $98,89 \pm 0,78 \%$ por el descriptor CATAR, versus $98,81 \pm 1,74 \%$ reportado por Calvo y Holguín para el mismo experimento, logrando deducir la desviación del $1,74 \%$ al $0,78 \%$ con la implementación del descriptor CATAR. Con los resultados obtenidos también se puede identificar que los descriptores basados en modelos autorregresivos no se quedan atrás en la capacidad de mejorar un sistema de clasificación, en dos de los cuatro experimentos realizados, el escritor CATAR, señales EMG concatenadas y caracterizadas por modelos autorregresivos presentaron los mejores resultados, se evidencia que es precisamente en los experimento que involucran los datos del Kinect, pero sería necesario hacer un diseño experimental para probar alguna correlación.

Figura 5. Matriz de confusión Actividades físicas - Descriptor CATAR



Las técnicas basadas en la implementación de la transformada Wavelet presentaron los mejores resultados, lo cual es afín a lo presentado en el estado del arte, e incluso permitió que los

resultados obtenidos por Calvo y Holguín presentara resultados aceptables desde las señales EMG, Sin embargo, las técnicas como los modelos autorregresivos pueden aun ser ampliamente exploradas y desarrollar experimentación usando curvas ROC para validar su potencial en la clasificación.

8.2. RECOMENDACIONES

El trabajo con señales EMG es un nicho amplio para la investigación de técnicas de caracterización, aun quedan metodologías por implementar en cuanto a los métodos basados en sistemas adaptativos y probar combinaciones de metodológicas como la propuesta en este trabajo usando Wavelet como un método de descomposición modal y aplicando técnicas como AR, FFT, momentos estadísticos, entre otros. En el desarrollo de este trabajo se logro demostrar que los descriptores propuestos mejoran la capacidad de clasificación de la metodología propuesta por Calvo y Holguín en [8] y que se puede observar en la figura 1.

Una de las limitantes del proceso fue la cantidad de sensores usados en la adquisición de datos, para una mejora en el proceso de identificación seria útil aumentar la cantidad de sensores por extremidad permitiendo obtener valores diferenciales que pueden entregar mas información sobre la actividad muscular de un individuo. Ya se han adelantado algunos análisis parciales realizando la adquisición de datos desde un sensor EMG denominado *Myo Armband* pues este sensor cuenta con 8 sensores dispuestos en forma de brazalete y comunicación Bluetooth con una capacidad de muestreo de 200Hz, características deseables en cuanto al aporte de las señales EMG a la identificación de actividades físicas.

BIBLIOGRAFÍA

- [1] BAÑOS, Oresti; POMARES, Héctor y ROJAS, Ignacio. Hibridación de paradigmas de clasificación en el contexto del reconocimiento automático de actividades físicas cotidianas. En: ESTYLF, Congreso Español sobre Tecnologías y Lógica Fuzzy, 2010. 1.1, 1.2
- [2] LI, Kang y FU, Yun. ARMA-HMM: A New Approach for Early Recognition of Human Activity. 21, 2012, págs. 11–15. 1.1
- [3] ZHANG, Zequn, *et al.* A novel method for user-defined human posture recognition using Kinect. En: Image and Signal Processing (CISP), 2014 7th International Congress on, 2014, págs. 736–740. 1.1, 1.2
- [4] HAZARIKA, A., *et al.* Two-fold feature extraction technique for biomedical signals classification. En: 2016 International Conference on Inventive Computation Technologies (ICICT), tomo 2, 2016, págs. 1–4. 1.1, 1.2, 2, 8.1
- [5] GYLLENSTEN, Illpha Cuba. Physical Activity Recognition in Daily Life using a Triaxial Accelerometer. Tesis de Maestría, School of Computer Science and Engineering Royal Institute of Technology, 2010. 1.1
- [6] ZHANG, Bingke y ZHANG, Shiyu. The estimation of grasping force based on the feature extracted from EMG signals. En: 2016 IEEE Advanced Information Management, Communicates, Electronic and Automation Control Conference (IMCEC), 2016, págs. 1477–1480. 1.1, 2
- [7] D, Leightley, *et al.* Human Activity Recognition for Physical Rehabilitation. En: Systems, Man, and Cybernetics (SMC), 2013 IEEE International Conference on, 2013, págs. 261–266. 1.1
- [8] SALCEDO, Andrés Felipe Calvo. Reconocimiento Automático Actividades Física Humanas en Sistema Multimodales. Tesis de Maestría, Universidad Tecnológica de Pereira,

- Programa de Ingeniería Eléctrica, 2015. 1.1, 1.2, 5, 5.1, 5.1, 5.2, 5.6, 6, 17, 7.1, 7.2.2, 7.2.4, 8.1, 8.2
- [9] GARG, C.; NARAYAN, Y. y MATHEW, L. Development of a software module for feature extraction and classification of EMG signals. En: 2015 Communication, Control and Intelligent Systems (CCIS), 2015, págs. 250–254. 1.1, 1.2, 2, 8.1
- [10] JINGEN LIU, Saad Ali y SHAH, Mubarak. Recognizing Human Actions Using Multiple Features. En: Computer Vision and Pattern Recognition, 2008. 1.1, 1.2
- [11] DUONG, T.V., Bui H.H. Phung D.Q. Activity Recognition and Abnormality Detection with the Switching Hidden Semi-Markov Model. En: Computer Society Conference on Computer Vision and Pattern Recognition (CVPR), 2005. 1.1
- [12] BLANK, M. Gorelick, L. Shechtman E. Irani M. y BASRI, R. Actions as Space-time Shapes. En: Tenth IEEE International Conference on Computer Vision, 2005. 1.1
- [13] BAO, L. y INTILLE, S. S. Activity recognition from user-annotated acceleration data. En: in Proceedings of the 2nd International Conference on Pervasive Computing, 2004, págs. 1–17. 1.1, 1.2
- [14] DE CASTRO, David Martín. Aplicación Android para el reconocimiento automático de actividades físicas en tiempo real. Tesis de Maestría, Universidad Carlos III de Madrid Departamento de Informática, 2012. 1.1
- [15] ZHANG, Mi y SAWCHUK, Alexander A. A feature selection-based framework for human activity recognition using wearable multimodal sensors. En: In International Conference on Body Area Networks (BodyNets), Beijing, China, 2011. 1.1
- [16] ERTUÄRUL, Ä. F., *et al.* EMG signal classification by extreme learning machine. En: 2013 21st Signal Processing and Communications Applications Conference (SIU), 2013, págs. 1–4. 1.1, 2, 8.1

- [17] HAZARIKA, A., *et al.* Fusion of projected feature for classification of EMG patterns. En: 2016 International Conference on Accessibility to Digital World (ICADW), 2016, págs. 69–74. 1.1, 1.2, 2, 8.1
- [18] BAÑOS, O., *et al.* Kinect=IMU? Learning MIMO Signal Mappings to Automatically Translate Activity Recognition Systems across Sensor Modalities. En: Wearable Computers (ISWC), 2012 16th International Symposium on, 2012. ISSN 1550-4816, págs. 92–99. 1.1
- [19] LIU, Kui, *et al.* Multi-HMM classification for hand gesture recognition using two differing modality sensors. En: Circuits and Systems Conference (DCAS), 2014 IEEE Dallas, 2014, págs. 1–4. 1.1
- [20] BURMEISTER, O.P., *et al.* Synchronous stereo-video and biosignal recording - a basic setup for Human-Computer-Interface applications. En: Neural Engineering, 2005. Conference Proceedings. 2nd International IEEE EMBS Conference on, 2005, págs. 501–505. 1.1
- [21] DESTELLE, F., *et al.* Low-cost accurate skeleton tracking based on fusion of kinect and wearable inertial sensors. En: Signal Processing Conference (EUSIPCO), 2014 Proceedings of the 22nd European, 2014, págs. 371–375. 1.1
- [22] BHATTACHARYA, A.; SARKAR, A. y BASAK, P. Time domain multi-feature extraction and classification of human hand movements using surface EMG. En: 2017 4th International Conference on Advanced Computing and Communication Systems (ICACCS), 2017, págs. 1–5. 1.1, 2
- [23] AL-QURAISHI, M. S., *et al.* Impact of feature extraction techniques on classification accuracy for EMG based ankle joint movements. En: 2015 10th Asian Control Conference (ASCC), 2015, págs. 1–5. 1.1, 1.2, 2, 8.1

- [24] DONOVAN, I. M., *et al.* Simple space-domain features for low-resolution sEMG pattern recognition. En: 2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), 2017. ISSN 1557-170X, págs. 62–65. 1.1, 2, 8.1
- [25] KHUSHABA, R. N., *et al.* Myoelectric feature extraction using temporal-spatial descriptors for multifunction prosthetic hand control. En: 2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), 2016. ISSN 1557-170X, págs. 1696–1699. 1.1, 1.2, 2, 8.1
- [26] JU, Z., *et al.* Surface EMG Based Hand Manipulation Identification Via Nonlinear Feature Extraction and Classification. En: IEEE Sensors Journal, tomo 13, nº 9, 2013, págs. 3302–3311. ISSN 1530-437X. 1.1, 1.2, 2, 8.1
- [27] PIL LEE, Seok; SUB KIM, Jung y HUI PARK, Sang. An enhanced feature extraction algorithm for EMG pattern classification. En: IEEE Transactions on Rehabilitation Engineering, tomo 4, nº 4, 1996, págs. 439–443. ISSN 1063-6528. 1.1, 1.2, 2
- [28] MISHRA, V. K.; BAJAJ, V. y KUMAR, A. Classification of normal, ALS, and myopathy EMG signals using ELM classifier. En: 2016 2nd International Conference on Advances in Electrical, Electronics, Information, Communication and Bio-Informatics (AEEICB), 2016, págs. 455–459. 1.1, 2
- [29] FERGUSON, S. y DUNLOP, R. G. Grasp recognition from myoelectric signals. En: Australasian Conference on Robotics and Automation, 2002. 1.1, 2, 8.1
- [30] DAISUKE, N. Studies on electromyogram to motion classifier. Tesis Doctoral, Hokkaido University, 2001. 1.1, 2, 8.1
- [31] MORALES, Santiago. Identificación de actividad humana usando aprendizaje no supervisado en sistemas multimodales. Tesis de Maestría, Universidad Tecnológica de Pereira, Programa de Ingeniería Eléctrica, 2016. 1.1, 1.2, 5

- [32] FOERSTER, Friedrich y FAHRENBERG. Motion pattern and posture: Correctly assessed by calibrated accelerometers. En: Behavior Research Methods, Instruments, & Computers, 2000. 1.2
- [33] LU, X, Liu Q y S, Oe. Recognizing Non-rigid Human Actions using Joints Tracking in Space-Time. En: Conference on Information Technology: Coding and Computing, 2004. 1.2
- [34] WU, Haitao, *et al.* Human activity recognition based on the combined SVM amp;HMM. En: Information and Automation (ICIA), 2014 IEEE International Conference on, 2014, págs. 219–224. 1.2
- [35] BOSE, R.; SAMANTA, K. y CHATTERJEE, S. Cross-correlation based feature extraction from EMG signals for classification of neuro-muscular diseases. En: 2016 International Conference on Intelligent Control Power and Instrumentation (ICICPI), 2016, págs. 241–245. 1.2, 2, 8.1
- [36] NEGI, S.; KUMAR, Y. y MISHRA, V. M. Feature extraction and classification for EMG signals using linear discriminant analysis. En: 2016 2nd International Conference on Advances in Computing, Communication, Automation (ICACCA) (Fall), 2016, págs. 1–6. 1.2, 2
- [37] FADLULLAH, Z. M., *et al.* State-of-the-Art Deep Learning: Evolving Machine Intelligence Toward Tomorrow's Intelligent Network Traffic Control Systems. En: IEEE Communications Surveys Tutorials, tomo 19, nº 4, 2017, págs. 2432–2455. 1.2, 3.4
- [38] ALI, E. A. H. y MOHAMED, A. Y. S. Modeling of human hand fingers states using electromyography and logistic regression. En: 2016 Conference of Basic Sciences and Engineering Studies (SGCAC), 2016, págs. 38–42. 1.2, 2, 4.5, 8.1
- [39] POMBOZA-JUNEZ, G. y TERRIZA, J. H. Hand gesture recognition based on sEMG signals using Support Vector Machines. En: 2016 IEEE 6th International Conference on Consumer Electronics - Berlin (ICCE-Berlin), 2016, págs. 174–178. 2

- [40] GRAUPE, D. EMG pattern analysis for patient-responsive control of FES in paraplegics for walker-supported walking. En: Biomedical Engineering, IEEE Transactions on, tomo 36, n^o 7, 1989, págs. 711–719. ISSN 0018-9294. 2
- [41] K. FARRY, I. Walker y BARANIUK, R. Myoelectric teleoperation of a complex robotic hand. En: IEEE Transactions On Robotic and Automation, tomo 12, n^o 5, 1996. 2
- [42] KANG, Wen-Juh, *et al.* The application of cepstral coefficients and maximum likelihood method in EMG pattern recognition [movements classification]. En: Biomedical Engineering, IEEE Transactions on, tomo 42, n^o 8, 1995, págs. 777–785. ISSN 0018-9294. 2
- [43] ZHANG, Y., *et al.* Performance evaluation of Noise-Assisted Multivariate Empirical Mode Decomposition and its application to multichannel EMG signals. En: 2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), 2017. ISSN 1557-170X, págs. 3457–3460. 2, 8.1
- [44] C. JORGENSEN, K. Wheeler y STEPNIIEWSKI, S. Bioelectric control of a 757 class high fidelity aircraft simulation. En: World Automation Congress, Wailea, Maui, Hawaii, 2000. 2, 8.1
- [45] AKANSU, Ali N Haddad y A., Richard. Multiresolution signal decomposition: transforms, subbands, and wavelets. Boston, MA: Academic Press, 1992. 3.1
- [46] TYAGI, V. y WELLEKENS, C. "Shape Activity": a continuous-state HMM for moving/deforming shapes with application to abnormal activity detection. En: IEEE International Conference In Acoustics, Speech, and Signal Processing,, 2005. 3.2
- [47] FANG ZHENG, Guoliang Zhang y SONG, Zhanjiang. Comparison of Different Implementations of MFCC. En: Computer Science and Technology, tomo 16, n^o 6, 2001, págs. 582–589. 3.2
- [48] HAYKIN, Simon. Adaptive Filter Theory. Second edition ed^{ón}. Prentice-Hall International, Inc., 1991. ISBN 0-13-005513-1. 3.3

- [49] SCHÖLKOPF, Bernhard, Smola y J, Alexander. Learning with Kernels. MIT Press, 2002. 3.4
- [50] CRAMMER, Koby y SINGER, Yoram. On the Algorithmic Implementation of Multiclass Kernel-based Vector Machines. En: J of Machine Learning Research, 2001. 3.5
- [51] RABINER, Lawrence R. A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition. En: Proceedings of the IEEE, tomo 77, nº 2, 1989. 3.6
- [52] EETIMES. GPS system with IMUs tracks first responders. R. Colin Johnson. 4.1
- [53] MICROSOFT. Kinect for Windows Technical Datasheet. Partner Network. 4.2
- [54] GIRALDO S, Eduardo y OROZCO GUTIÉRREZ, Alvaro A. Sistema automatizado efectivo y apropiado de caraterización y clasificación de señales electromiográficas para el control de prótesis y brazos robóticos. Inf. téc., Colciencias Colombia., 2008. 4.3
- [55] GUYON, Isabelle y ELISSEEFF, André. Foundations and Applications Studies in Fuzziness and Soft Computing: An Introduction to Feature Extraction. Springer Verlag, 2006. 4.4
- [56] MEHRYAR MOHRI, Afshin Rostamizadeh y TALWALKAR, Ameet. Foundations of Machine Learning. The MIT Press, 2012. 4.6, 4.9
- [57] GHASEMZADEH, H., *et al.* A phonological expression for physical movement monitoring in body sensor networks. En: Mobile Ad Hoc and Sensor Systems, 2008. MASS 2008. 5th IEEE International Conference on, 2008, págs. 58–68. 5
- [58] HUANG, Xuedong; ACERO, Alex y HON, Hsiao-Wuen. Spoken Language Processing: A Guide to Theory, Algorithm, and System Development. 1ª ed^{ón}. Prentice Hall PTR, Upper Saddle River, NJ, USA, 2001. ISBN 0130226165. 5

9. ANÉXOS

9.1. Matrices de Confusión movimientos primitivos

Figura 6. Matrices de confusión Movimientos primitivos - Descriptor DFT (Izq. Señales Individuales - Der. Señales concatenadas)




Figura 7. Matrices de confusión Movimientos primitivos - Descriptor AR (Izq. Señales Individuales - Der. Señales concatenadas)

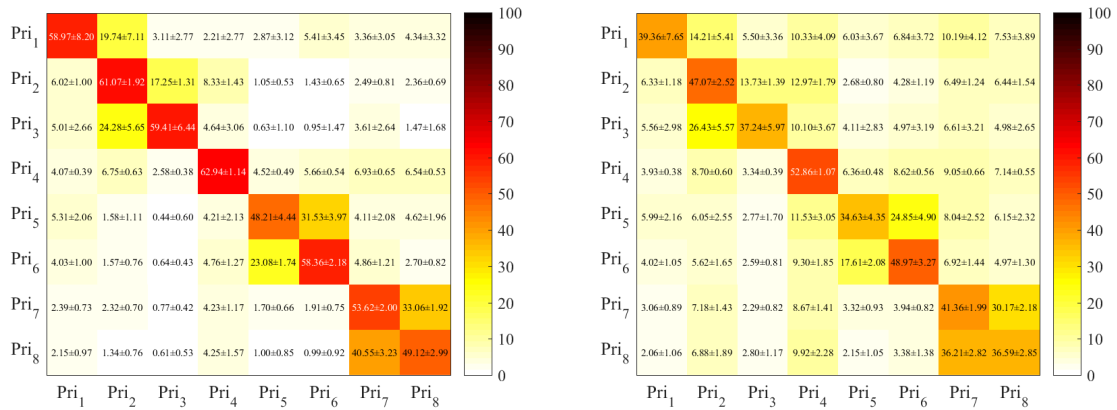


Figura 8. Matrices de confusión Movimientos primitivos - Descriptor Wavelet concatenado coeficientes de aproximación y detalle (Izq. Señales Individuales - Der. Señales concatenadas)

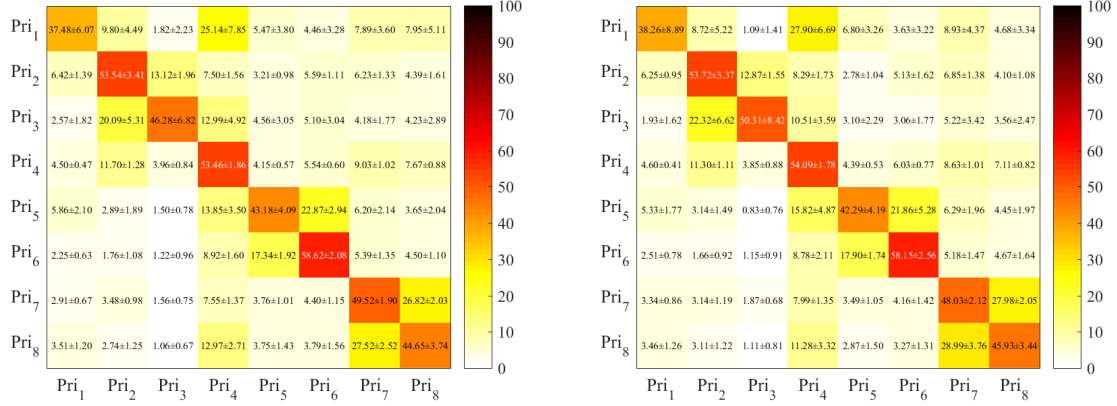


Figura 9. Matrices de confusión Movimientos primitivos - Descriptor Wavelet descomposición de orden superior (Izq. Señales Individuales - Der. Señales concatenadas)

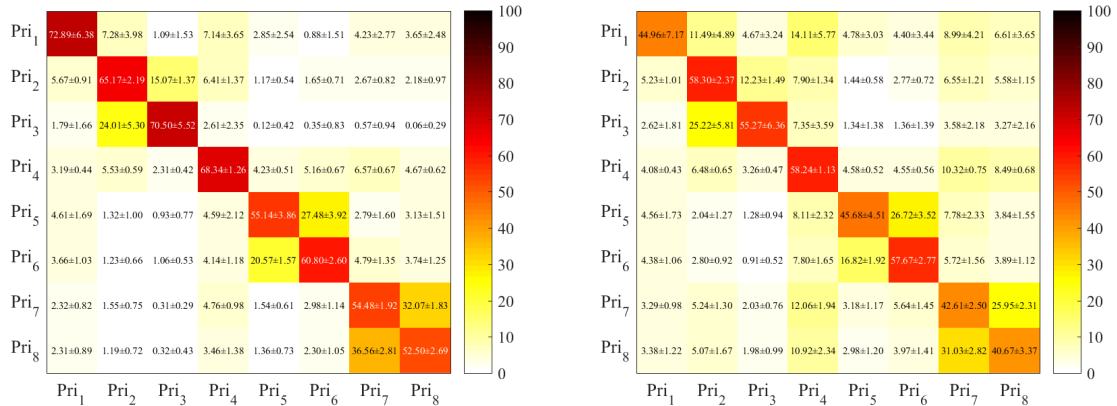


Figura 10. Matrices de confusión Movimientos primitivos - Descriptor Wavelet FFT (Izq. Señales Individuales - Der. Señales concatenadas)

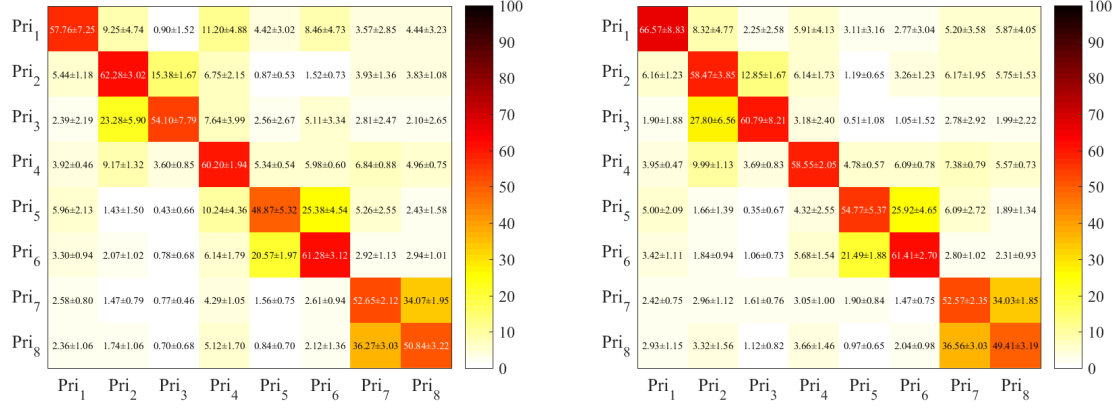


Figura 11. Matrices de confusión Movimientos primitivos - Descriptor Wavelet AR (Izq. Señales Individuales - Der. Señales concatenadas)

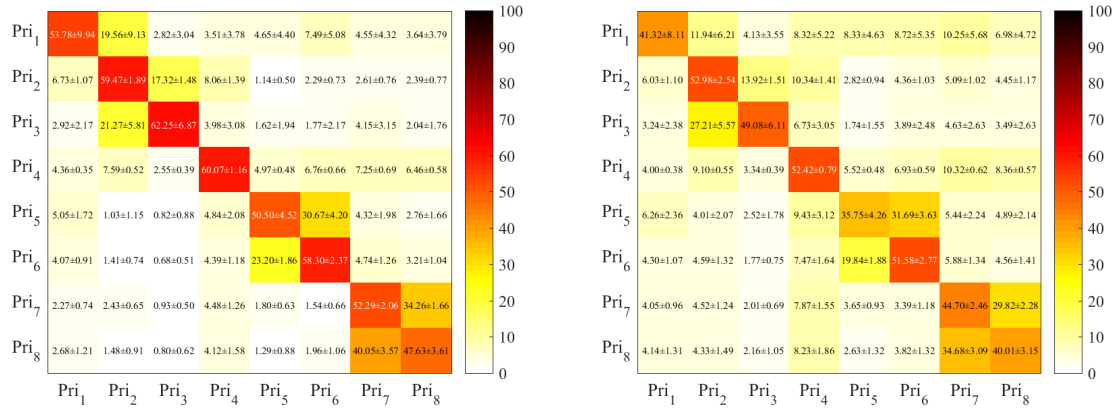


Figura 12. Matrices de confusión Movimientos primitivos - Descriptor Wavelet Estadísticos (Izq. Señales Individuales - Der. Señales concatenadas)

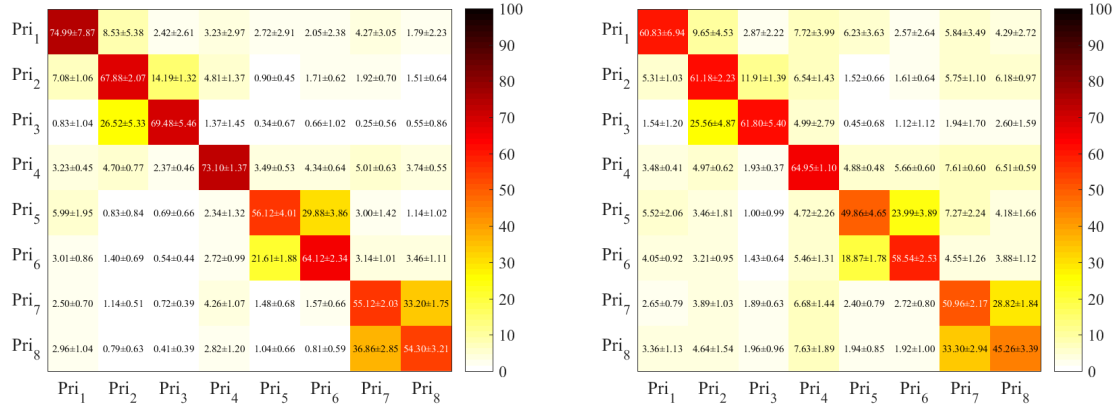
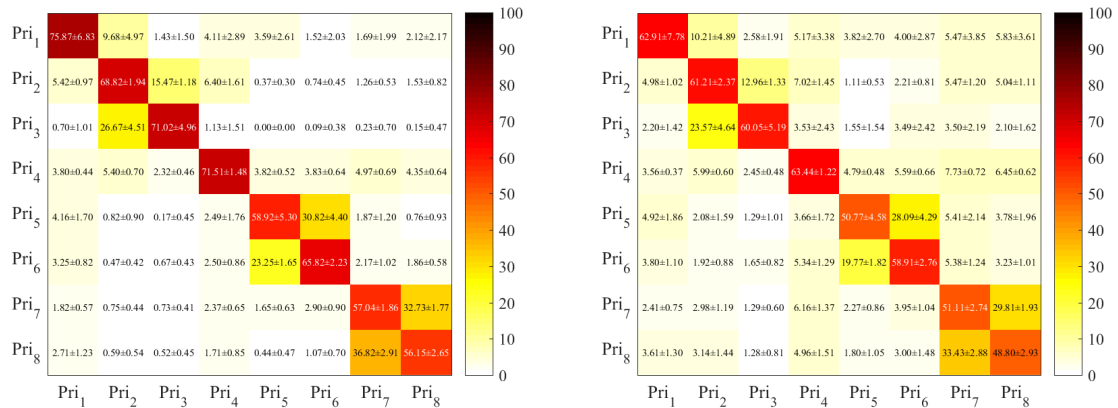


Figura 13. Matrices de confusión Movimientos primitivos - Wavelet Estadísticos y energía (Izq. Señales Individuales - Der. Señales concatenadas)



9.2. Matrices de Confusión actividades físicas

9.2.1. Experimento EMG

Figura 14. (Experimento EMG) Matrices de confusión Actividades físicas - Descriptor DFT (Izq. Señales Individuales - Der. Señales concatenadas)




Figura 15. (Experimento EMG) Matrices de confusión Actividades físicas - Descriptor AR (Izq. Señales Individuales - Der. Señales concatenadas)




Figura 16. (Experimento EMG) Matrices de confusión Actividades físicas - Descriptor Wavelet concatenado coeficientes de aproximación y detalle (Izq. Señales Individuales - Der. Señales concatenadas)




Figura 17. (Experimento EMG) Matrices de confusión Actividades físicas - Descriptor Wavelet descomposición de orden superior (Izq. Señales Individuales - Der. Señales concatenadas)




Figura 18. (Experimento EMG) Matrices de confusión Actividades físicas - Descriptor Wavelet FFT (Izq. Señales Individuales - Der. Señales concatenadas)




Figura 19. (Experimento EMG) Matrices de confusión Actividades físicas - Descriptor Wavelet AR (Izq. Señales Individuales - Der. Señales concatenadas)




Figura 20. (Experimento EMG) Matrices de confusión Actividades físicas - Descriptor Wavelet Estadísticos (Izq. Señales Individuales - Der. Señales concatenadas)


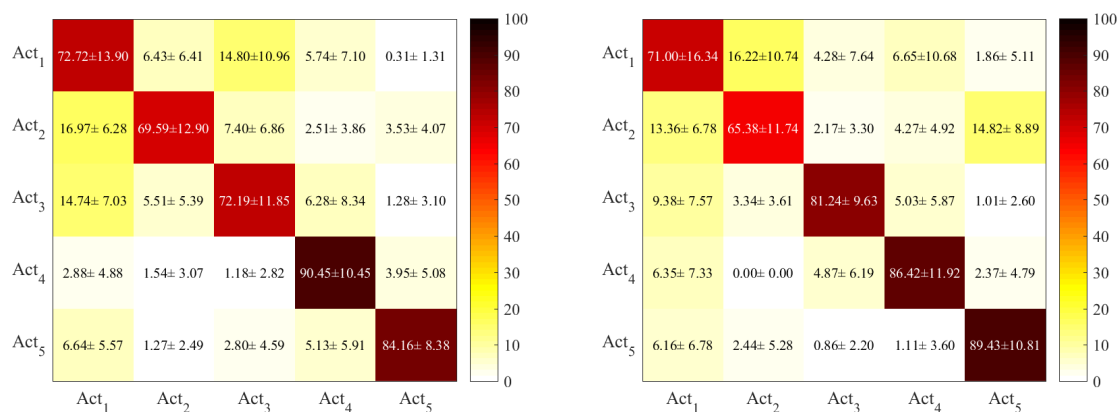


Figura 21. (Experimento EMG) Matrices de confusión Actividades físicas - Wavelet Estadísticos y energía (Izq. Señales Individuales - Der. Señales concatenadas)



9.2.2. Experimento EMG+Kinect

Figura 22. (Experimento EMG+Kinect) Matrices de confusión Actividades físicas - Descriptor DFT (Izq. Señales Individuales - Der. Señales concatenadas)

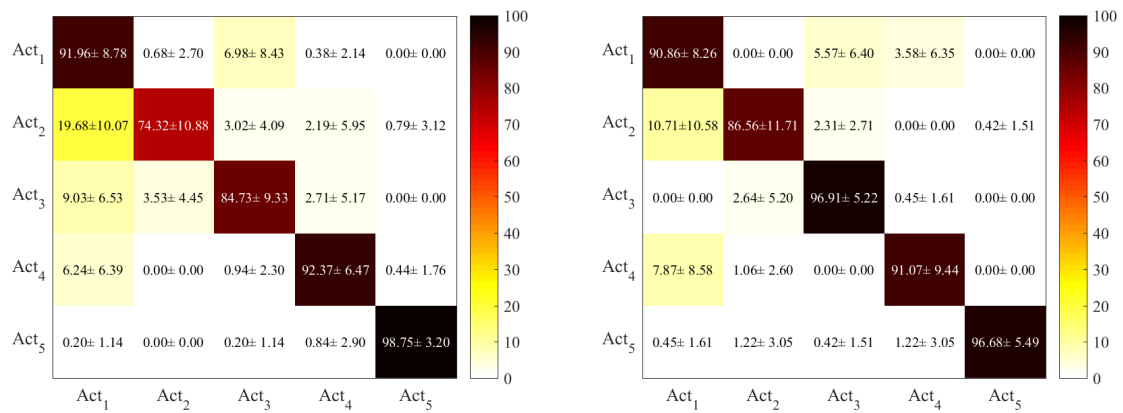


Figura 23. (Experimento EMG+Kinect) Matrices de confusión Actividades físicas - Descriptor AR (Izq. Señales Individuales - Der. Señales concatenadas)

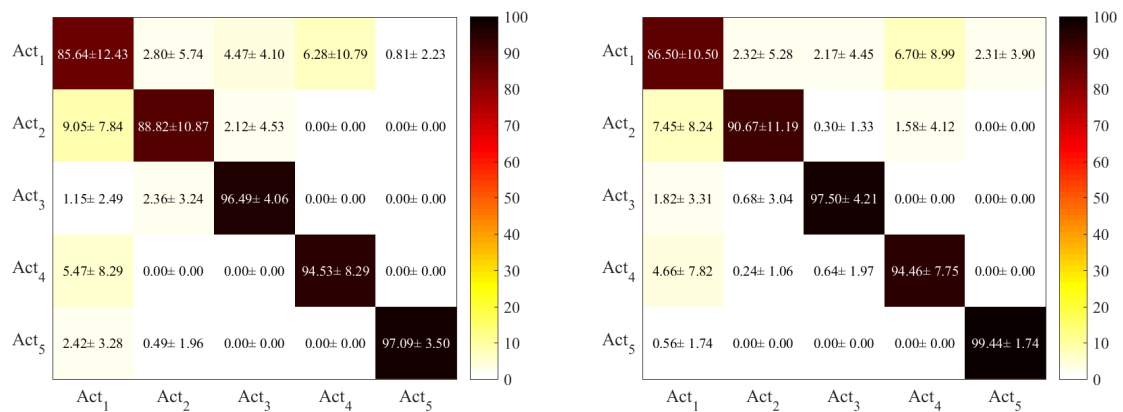


Figura 24. (Experimento EMG+Kinect) Matrices de confusión Actividades físicas - Descriptor Wavelet concatenado coeficientes de aproximación y detalle (Izq. Señales Individuales - Der. Señales concatenadas)




Figura 25. (Experimento EMG+Kinect) Matrices de confusión Actividades físicas - Descriptor Wavelet descomposición de orden superior (Izq. Señales Individuales - Der. Señales concatenadas)

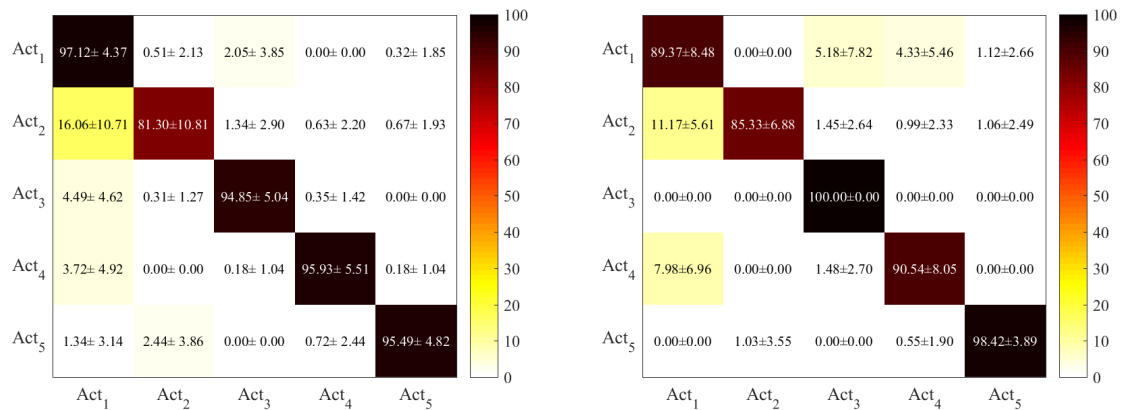


Figura 26. (Experimento EMG+Kinect) Matrices de confusión Actividades físicas - Descriptor Wavelet FFT (Izq. Señales Individuales - Der. Señales concatenadas)

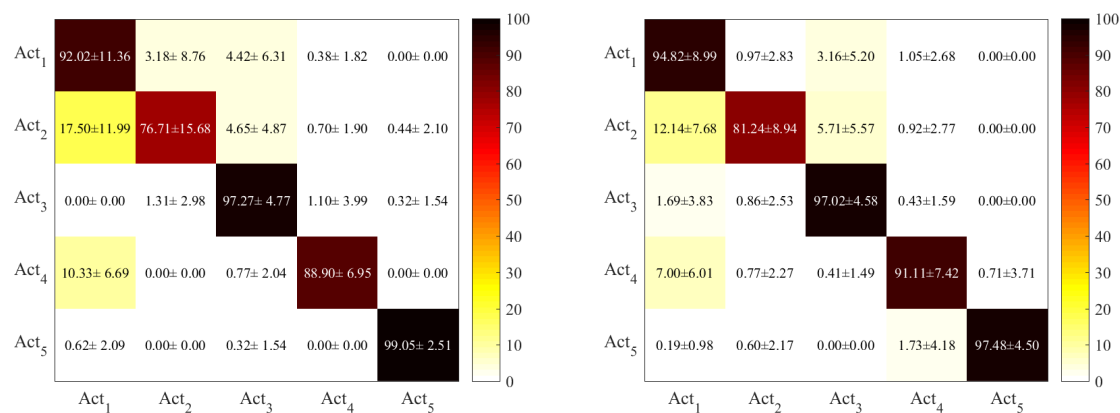


Figura 27. (Experimento EMG+Kinect) Matrices de confusión Actividades físicas - Descriptor Wavelet AR (Izq. Señales Individuales - Der. Señales concatenadas)

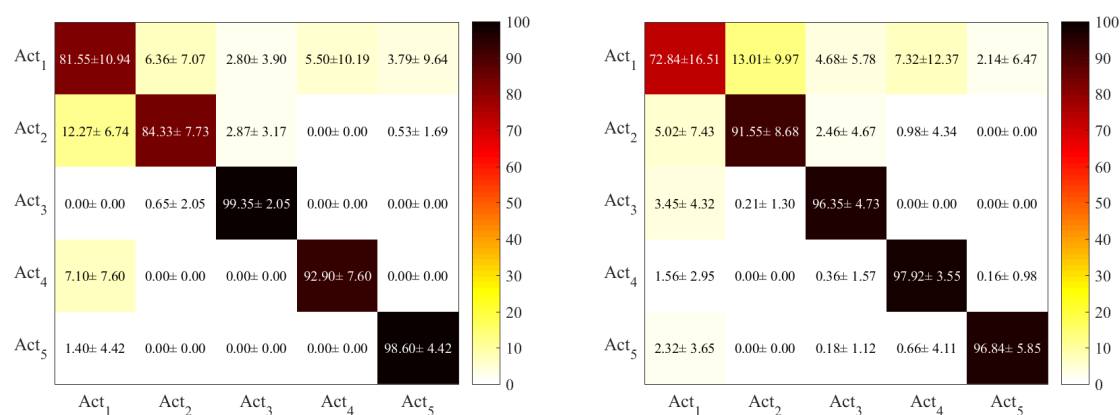


Figura 28. (Experimento EMG+Kinect) Matrices de confusión Actividades físicas - Descriptor Wavelet Estadísticos (Izq. Señales Individuales - Der. Señales concatenadas)

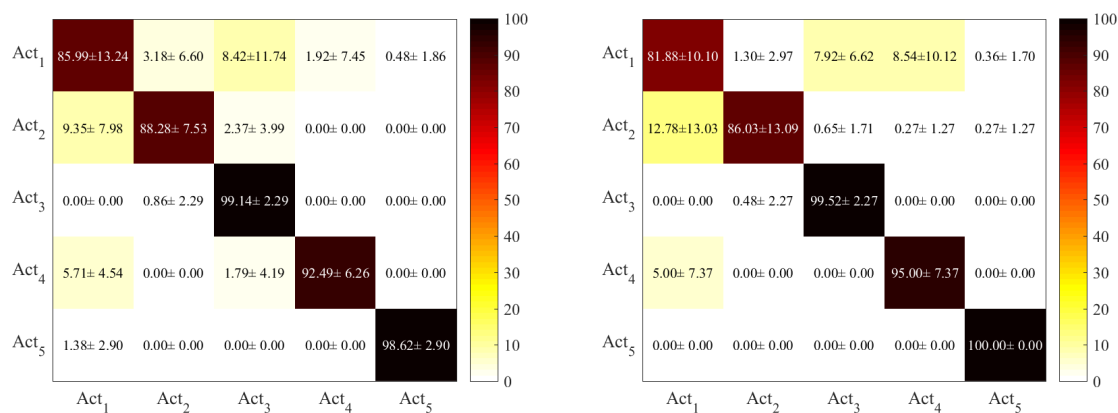
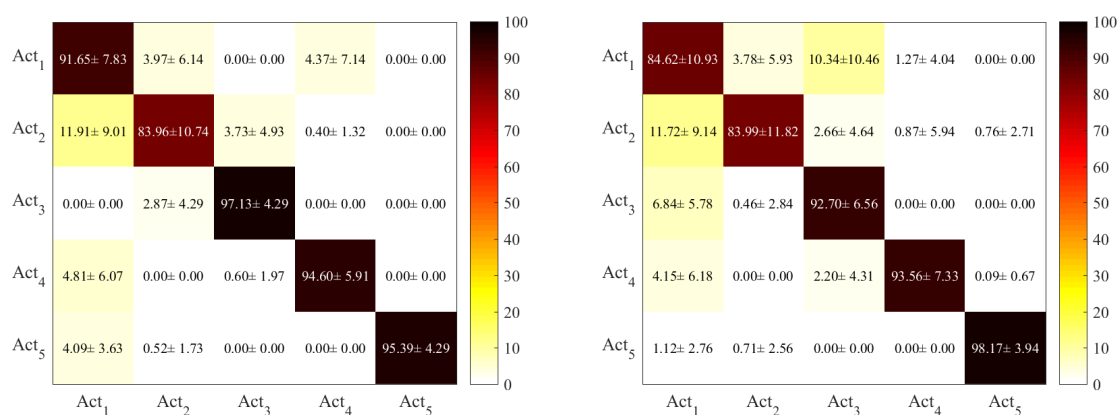


Figura 29. (Experimento EMG+Kinect) Matrices de confusión Actividades físicas - Wavelet Estadísticos y energía (Izq. Señales Individuales - Der. Señales concatenadas)



9.2.3. Experimento EMG+IMU

Figura 30. (Experimento EMG+IMU) Matrices de confusión Actividades físicas - Descriptor DFT (Izq. Señales Individuales - Der. Señales concatenadas)

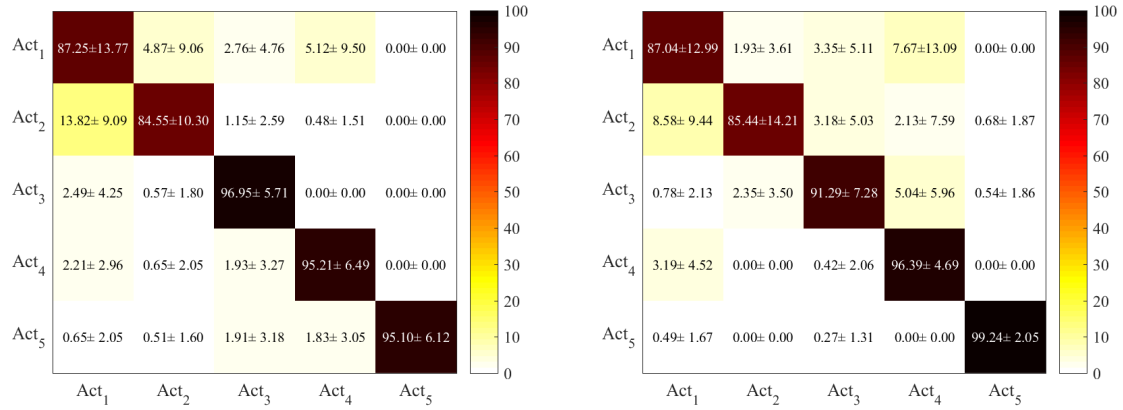


Figura 31. (Experimento EMG+IMU) Matrices de confusión Actividades físicas - Descriptor AR (Izq. Señales Individuales - Der. Señales concatenadas)




Figura 32. (Experimento EMG+IMU) Matrices de confusión Actividades físicas - Descriptor Wavelet concatenado coeficientes de aproximación y detalle (Izq. Señales Individuales - Der. Señales concatenadas)




Figura 33. (Experimento EMG+IMU) Matrices de confusión Actividades físicas - Descriptor Wavelet descomposición de orden superior (Izq. Señales Individuales - Der. Señales concatenadas)

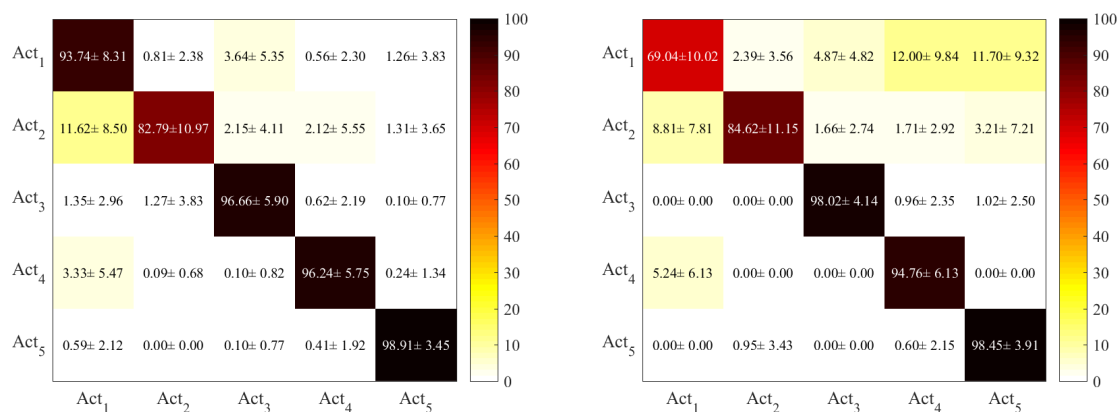


Figura 34. (Experimento EMG+IMU) Matrices de confusión Actividades físicas - Descriptor Wavelet FFT (Izq. Señales Individuales - Der. Señales concatenadas)

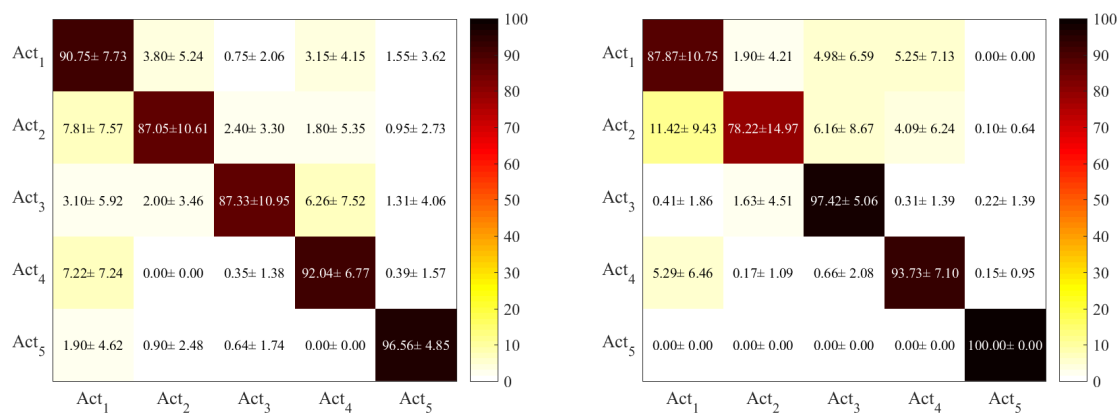


Figura 35. (Experimento EMG+IMU) Matrices de confusión Actividades físicas - Descriptor Wavelet AR (Izq. Señales Individuales - Der. Señales concatenadas)

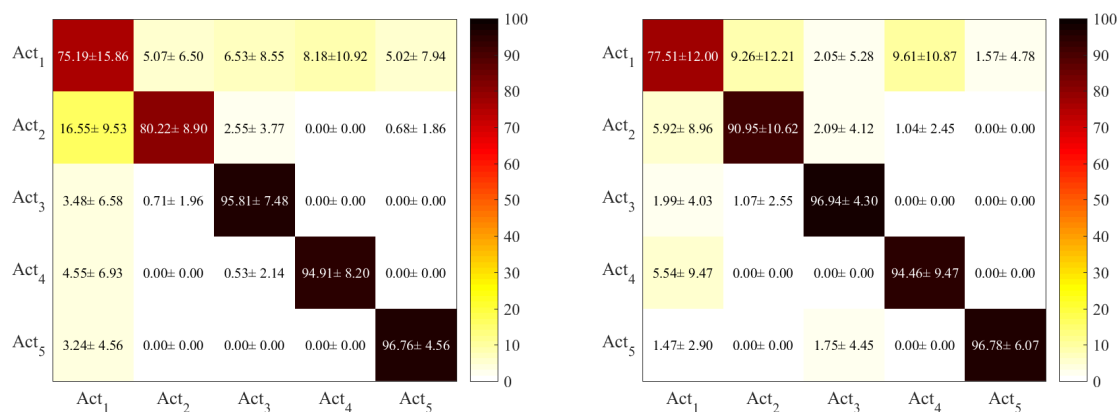


Figura 36. (Experimento EMG+IMU) Matrices de confusión Actividades físicas - Descriptor Wavelet Estadísticos (Izq. Señales Individuales - Der. Señales concatenadas)

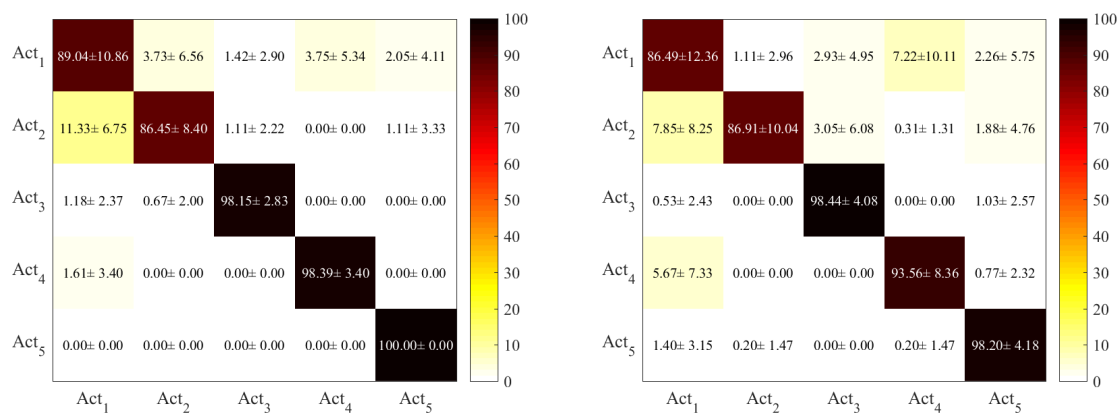
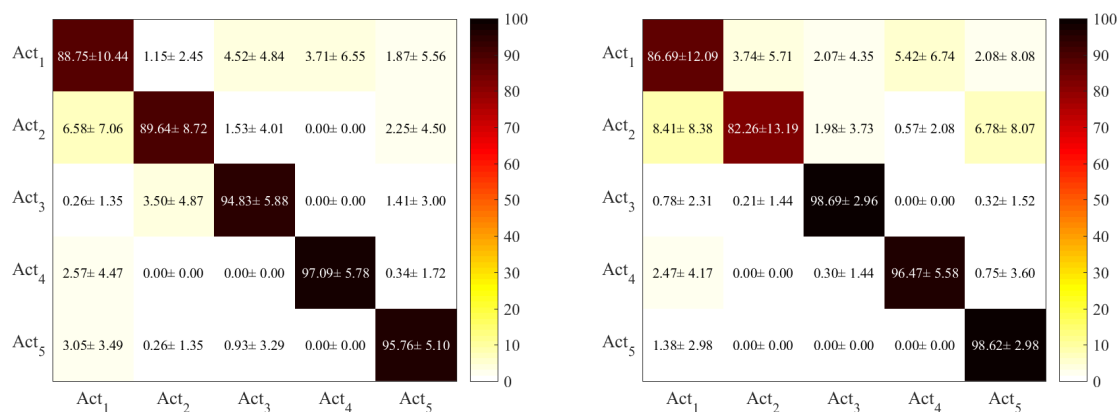


Figura 37. (Experimento EMG+IMU) Matrices de confusión Actividades físicas - Wavelet Estadísticos y energía (Izq. Señales Individuales - Der. Señales concatenadas)



9.2.4. Experimento EMG+Kinect+IMU

Figura 38. (Experimento EMG+Kinect+IMU) Matrices de confusión Actividades físicas - Descriptor DFT (Izq. Señales Individuales - Der. Señales concatenadas)




Figura 39. (Experimento EMG+Kinect+IMU) Matrices de confusión Actividades físicas - Descriptor AR (Izq. Señales Individuales - Der. Señales concatenadas)

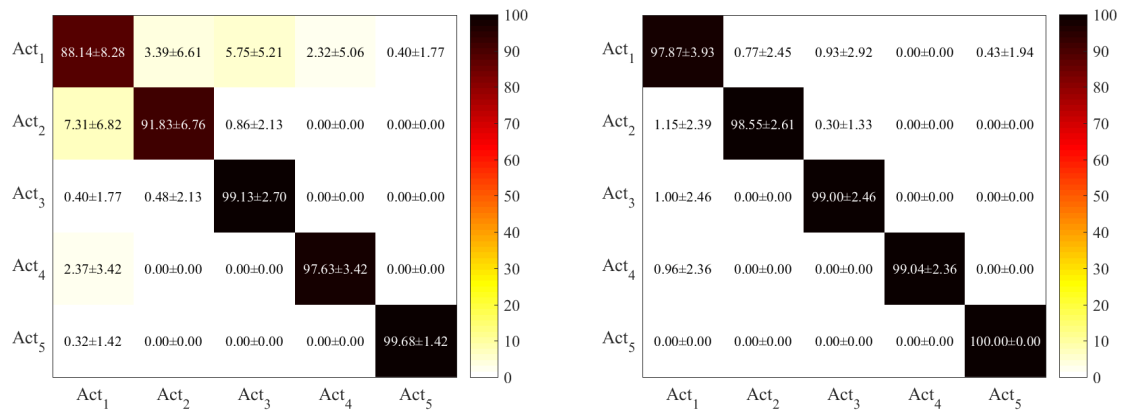


Figura 40. (Experimento EMG+Kinect+IMU) Matrices de confusión Actividades físicas - Descriptor Wavelet concatenado coeficientes de aproximación y detalle (Izq. Señales Individuales - Der. Señales concatenadas)




Figura 41. (Experimento EMG+Kinect+IMU) Matrices de confusión Actividades físicas - Descriptor Wavelet descomposición de orden superior (Izq. Señales Individuales - Der. Señales concatenadas)

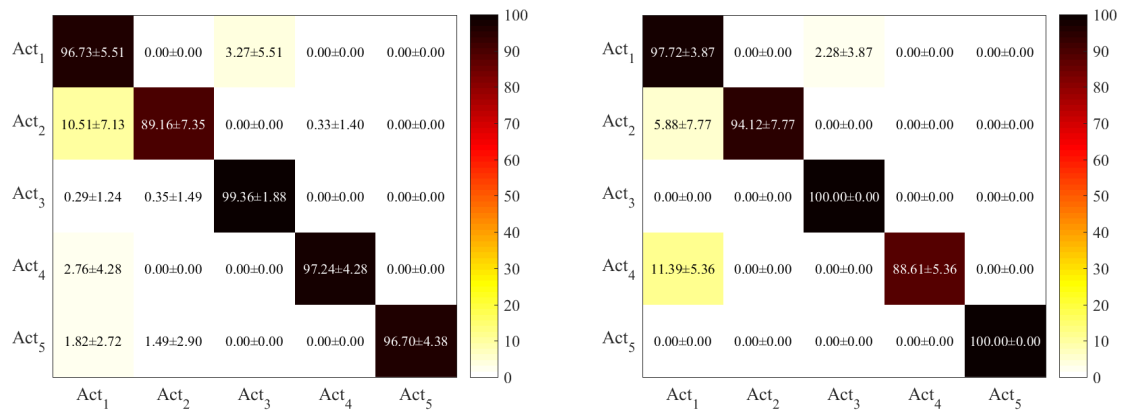


Figura 42. (Experimento EMG+Kinect+IMU) Matrices de confusión Actividades físicas - Descriptor Wavelet FFT (Izq. Señales Individuales - Der. Señales concatenadas)




Figura 43. (Experimento EMG+Kinect+IMU) Matrices de confusión Actividades físicas - Descriptor Wavelet AR (Izq. Señales Individuales - Der. Señales concatenadas)

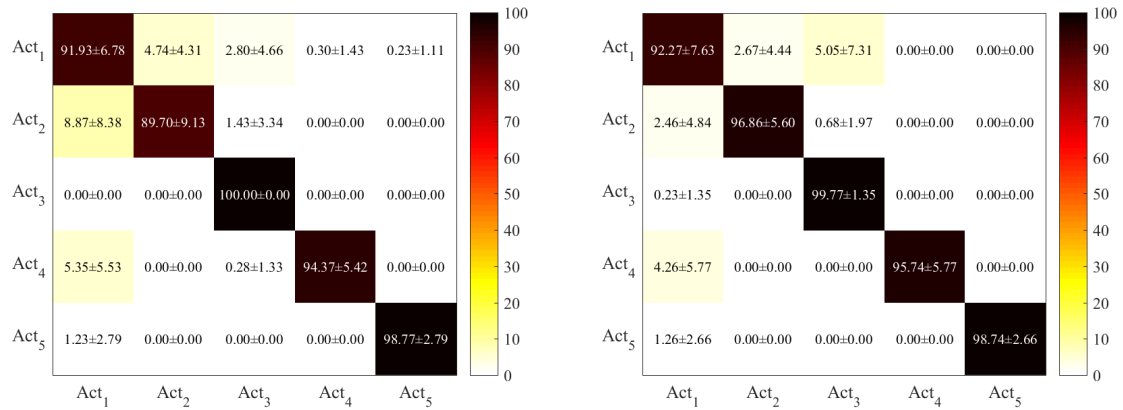


Figura 44. (Experimento EMG+Kinect+IMU) Matrices de confusión Actividades físicas - Descriptor Wavelet Estadísticos (Izq. Señales Individuales - Der. Señales concatenadas)




Figura 45. (Experimento EMG+Kinect+IMU) Matrices de confusión Actividades físicas - Wavelet Estadísticos y energía (Izq. Señales Individuales - Der. Señales concatenadas)

